T.C.
HARRAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME YÖNTEMLERİ İLE AYAKKABI GÖRÜNTÜLERİNİN SINIFLANDIRILMASI

Fatma Yeşim AYDİLEK

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

ŞANLIURFA
2020

Dr. Öğr. Üyesi Abdülkadir GÜMÜŞÇÜ danışmanlığında, Fatma Yeşim AYDİLEK'in hazırladığı "**Derin Öğrenme Yöntemleri ile Ayakkabı Görüntülerinin Sınıflandırılması**" konulu bu çalışma 14/01/2020 tarihinde aşağıdaki jüri tarafından oy birliği ile Harran Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

İmza

Danışman : Dr. Öğr. Üyesi Abdülkadir GÜMÜŞÇÜ .....

Üye : Dr. Öğr. Üyesi Mehmet Emin TENEKECİ .....

Üye : Dr.Öğr. Üyesi Abdurrahman ÖZBEYAZ .....

Bu Tezin Bilgisayar Mühendisliği Anabilim Dalında Yapıldığını ve Enstitümüz Kurallarına Göre Düzenlendiğini Onaylarım.

Doç. Dr. İsmail HİLALİ
Enstitü Müdürü

Not: Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirişlerin, çizelge, şekil ve fotoğrafların kaynak gösterilmeden kullanımı 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

İÇİNDEKİLER

Sayfa No

ÖZET ii
ABSTRACT iii
TEŞEKKÜR iv
ŞEKİLLER DİZİNİ v
ÇİZELGELER DİZİNİ vi
SİMGELER DİZİNİ vii
1. GİRİŞ 1
2. ÖNCEKİ ÇALIŞMALAR 4
3. MATERYAL ve YÖNTEM 8
3. 1 Veri Kümesi 8
3.2 Derin Öğrenme 9
3.2.1 Konvolüsyonel Sinir Ağları 11
3.2.2 Transfer Öğrenme 15
3.3 Önceden Eğitilmiş Derin Öğrenme Modelleri 16
3.3.1 AlexNet 16
3.3.2 InceptionV3 17
3.3.3 GoogLeNet 19
3.4 DVM (Destek Vektör Makinesi) 21
4. ARAŞTIRMA BULGULARI VE TARTIŞMA 22
4.1 Konvolüsyonel Sinir Ağı ile Yapılan Deneysel Çalışmalar 22
4.2 AlexNet ile Transfer Öğrenme Çalışması 31
4.3 InceptionV3 ile Transfer Öğrenme Çalışması 34
4.4 GoogLeNet ile Transfer Öğrenme Çalışması 37
5. SONUÇLAR VE ÖNERİLER 41
KAYNAKLAR 47
ÖZGEÇMİŞ 50

ÖZET

Yüksek Lisans Tezi

DERİN ÖĞRENME YÖNTEMLERİ İLE AYAKKABI GÖRÜNTÜLERİNİN SINIFLANDIRILMASI

Fatma Yeşim AYDİLEK

Harran Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Abdülkadir GÜMÜŞÇÜ,
YIL: 2020, Sayfa: 50

Günümüzde üretim sektöründe bir ürünün çok farklı çeşitleri üretilebilmektedir. Özellikle ayakkabı gibi tüm tüketicilerin temel bir ihtiyacı olan üründe çok fazla sayıda çeşitlilikte tercih bulunabilmektedir. Üretim sektöründeki artış, e-ticaretin yaygınlaşması gibi sebeplerden dolayı tüketicinin beğendiği ürünü bulabilmesi için çeşitli sınıflandırma tekniklerinden faydalanılmaktadır. Bu sınıflandırma tekniklerinden biri de oldukça popüler kullanımı olan derin öğrenme yaklaşımıdır. Sınıflandırma işleminin en doğru ve hızlı bir şekilde gerçekleştirilebilmesi için farklı yöntemlerin gelişimi devam etmektedir. Derin öğrenme yöntemi ile sınıflandırma yapılırken donanım maliyeti, zamandan tasarruf ve veri kümesinin yetersizliği gibi sorunların önüne geçebilmek için önceden eğitilmiş derin öğrenme modellerinden transfer öğrenme yöntemleri kullanılmaktadır. Bu tez çalışmasında, 107 farklı sınıf etiketi içeren ayakkabı görüntülerinden oluşan bir veri kümesi ile farklı önceden eğitilmiş derin öğrenme modelleri kullanılarak transfer öğrenme uygulamaları yapılmaktadır. Sıfırdan tasarlanan konvolüsyonel sinir ağları ile bu veri kümesi eğitilmektedir. Yapılan bu uygulamaların sınıflandırma doğruluk başarı oranları ve çalışma süreleri kıyaslanarak transfer öğrenmenin sağladığı avantajlar gözlemlenmektedir. Elde edilen deneysel çalışmaların sonuçlarına göre ayakkabı veri kümesi ile yapılan transfer öğrenme uygulamalarının, sıfırdan tasarlanan konvolüsyonel sinir ağlarından daha başarılı olduğu görülmektedir. Önceden eğitilmiş derin öğrenme modellerinden AlexNet modeli ile ince ayar transfer öğrenme yöntemi kullanılarak yapılan deneysel çalışma %72.87'lik sınıflandırma doğruluk başarı oranı ile bu tez çalışmasında yapılan diğer deneysel çalışmalara kıyasla en başarılı sonucu vermektedir.

ANAHTAR KELİMELER: Derin öğrenme, Transfer öğrenme, Konvolüsyonel sinir ağları, Ayakkabı veri kümesi

ABSTRACT

MSc Thesis

CLASSIFICATION OF SHOES IMAGES WITH DEEP LEARNING METHODS

Fatma Yeşim AYDİLEK

Harran University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

Supervisor: Assist. Prof. Dr. Abdülkadir GÜMÜŞÇÜ
Year: 2020, Page: 50

Nowadays, many different types of a product can be produced in the production sector. Especially in the product, which is a basic need of all consumers such as shoes, there are a large number of preferences. Various classification techniques are used for the consumer to find the product he/she likes due to reasons such as increase in the production sector and the spread of e-commerce. One of these classification techniques is deep learning approach, which is very popular recently. The development of different methods continues in order to perform the classification process in the most accurate and fastest way. Transfer learning methods from pre-trained deep models are used to avoid problems such as hardware cost, run time saving and insufficient data set while classifying with deep learning method. In this thesis, transfer learning applications are made using a data set consisting of 107 different class labels and different pre-trained deep learning models. Convolutional neural networks designed from the scratch are trained with this dataset. The advantages of transfer learning are observed by comparing the classification accuracy success rates and run times of these applications. According to the results of the experimental studies obtained, it is seen that the transfer learning applications with the shoes data set are more successful than the convolutional neural networks designed from the scratch. Experimental study using the fine-tuned transfer learning method with AlexNet model, which is one of the pre-trained deep learning models, gives the most successful result compared to other experimental studies in this thesis study with a classification accuracy rate of 72.87%.

KEY WORDS: Deep learning, Transfer learning, Convolutional neural network, Shoes dataset

TEŞEKKÜR

Aileme ve tez çalışmamın daha iyi bir noktaya gelmesindeki emek ve katkılarından dolayı danışmanım Sayın Dr. Öğr. Üyesi Abdülkadir GÜMÜŞÇÜ hocama teşekkürlerimi sunarım.

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 3.1. Ayakkabı veri kümesindeki bazı ayakkabı türlerine ait örnek ……. 10
görüntüler
Şekil 3.2. Derin öğrenme ile yorumlanmış görüntüler……...11
Şekil 3.3. Konvolüsyonel sinir ağı yapısı ……..12
Şekil 3.4. Konvolüsyonel katmanda filtrelerin kullanılma örneği ……13
Şekil 3.5. Havuzlama katmanı……14
Şekil 3.6. Tam bağlantılı katman……....15
Şekil 3.7. Sol tarafta kaçınma uygulanmamış yapay sinir ağı (YSA), sağ tarafta……..15
kaçınma uygulanmış YSA gösterilmektedir.
Şekil 3.8. AlexNet derin öğrenme modelinin mimari yapısı……..18
Şekil 3.9. InceptinV3 derin öğrenme modelinin yapısı ……..19
Şekil 3.10. GoogLeNet mimari yapısı……20
Şekil 4.1. Ayakkabı veri kümesi ile yapılan deneysel çalışmaların ana şeması……22
Şekil 4.2. 8 katmanlı KSA mimarisi……...23
Şekil 4.3. 17 katmanlı KSA mimarisi……26
Şekil 4.4. 20 katmanlı KSA mimarisi……29
Şekil 4.5. AlexNet özellik çıkarımı ve DVM ile sınıflandırma yöntemi akış şeması…….32
Şekil 4.6. AlexNet ince ayar yöntemi akış diyagramı……33
Şekil 4.7. InceptionV3 özellik çıkarımı ve DVM akış diyagramı……...35
Şekil 4.8. InceptionV3 ve ince ayar yöntemi akış diyagramı……...36
Şekil 4.9. GoogLeNet kullanılarak özellik çıkarımı ve SVM ile sınıflandırma……...38
akış diyagramı
Şekil 4.10. GoogLeNet ile ince ayar transfer öğrenme yöntemi akış diyagramı……39

ÇİZELGELER DİZİNİ

Sayfa No

Tablo 4.1. 8 katmanlı KSA ve 10 tekrarlama sayısı ile yapılan deneysel çalışma……24
Tablo 4.2. 8 katmanlı KSA ve 20 tekrarlama sayısından oluşan deneysel çalışma sonucu……..25
Tablo 4.3. 17 katmanlı KSA ve 10 tekrarlama sayısı ile yapılan deneysel çalışma sonuçları…..27
Tablo 4.4. 17 katmanlı KSA ve 20 tekrarlama sayısı ile yapılan deneysel çalışma sonucu…….28
Tablo 4.5 20 katmanlı KSA ve 10 tekrarlama sayısı ile yapılan deneysel çalışma…….30
Tablo 4.6. 20 Katmanlı KSA ve 20 tekrarlama sayısından oluşan……..…….....31
deneysel çalıma sonuçları
Tablo 4.7. AlexNet özellik çıkarımı yöntemi ve DVM ile sınıflandırma ……...33
sonuçları
Tablo 4.8. AlexNet ile ince ayar transfer öğrenme yöntemi sonuçları……....34
Tablo 4.9. InceptionV3 ile Özellik çıkarımı ve DVM sınıflandırma sonuçları……..36
Tablo 4.10. InceptionV3 derin öğrenme modeli ile ince ayar yöntemi sonuçları…….37
Tablo 4.11. GoogLeNet ile özellik çıkarımı yöntemi kullanılarak DVM ile……39
sınıflandırmada elde edilen sonuçlar
Tablo 4.12. GoogLeNet ile ince ayar yöntemi deneysel çalışmasından……40
elde edilen sonuçlar
Tablo 5.1. Tüm deneysel çalışmaların sonuçları…….42
Tablo 5.2. Literatürde ayakkabı veri kümesini sınıflandırmak için önerilen……..45
yöntemlerin sonuçları

SİMGELER DİZİNİ

DVM	Destek Vektör Makinesi
GİÜ	Grafik İşlemci Ünitesi
KSA	Konvolüsyonel Sinir Ağı
YSA	Yapay Sinir Ağı

1. GİRİŞ

Günümüzde teknolojinin ilerlemesi ile birlikte veri boyutlarının giderek artması, daha detaylı verilerin kullanılması ile verilerden anlamlı bilgiler elde edilmesi, verilerin kategorize edilmesi ve yeni gelen verinin hangi kategoriye ait olduğunun saptanması gittikçe zorlaşmaktadır (Aktan, E., 2018). Grafik işlemci ünitelerinin (GİÜ) yapay zeka hesaplamalarında kullanılması ve donanımsal gelişmeler sayesinde, çok sayıda gizli katmandan ve çok sayıda nöronlardan oluşan yapay sinir ağları ile hesaplama maliyetleri düşürülerek daha kısa sürede işlemler gerçekleştirilmektedir. Deneysel çalışmalarda kullanılan veri kümelerindeki görüntülere ait özelliklerin elde edilmesi için bir takım ön işlemler, boyut indirgeme, özellik seçme gibi işlemlerden geçirilmesi gerekmektedir.

Derin öğrenme yöntemleri günümüzde kullanım alanı gittikçe yaygınlaşan bir makine öğrenme yöntemidir (Şeker, A. ve ark., 2017). Literatürdeki farklı çalışmalarda derin öğrenme yöntemlerinin diğer makine öğrenme yöntemlerine göre büyük boyutlu veri kümelerinin işlenmesinde daha başarılı sonuçlar verdiği görülmektedir. Derin öğrenme ile görüntülerin özellikleri farklı bir takım filtreler kullanılarak çıkarılabilmektedir (Uçar, A. ve Bingöl, M., 2018). Çıkarılan bu özellik değerleri yapay sinir ağları gibi sınıflandırma algoritmalarında eğitilerek öğrenme işlemi gerçekleştirilmektedir. Derin öğrenme yöntemlerinin kullanıldığı alanlara görüntü işleme, ses ve video analizi, metin işleme gibi örnekler verilebilmektedir (Şeker, A. ve ark., 2017).

Derin öğrenme yöntemi ile büyük boyutlu veri kümeleri eğitilirken zamana ve donanım maliyeti yüksek olan GİÜ'lerine ihtiyaç duyulmaktadır (Kızrak, M. A. ve Bolat, B., 2018). Ayrıca sıfırdan tasarlanacak olan derin öğrenme ağının parametrelerinin en uygun şekilde belirlenmesi de deneme yanılma yoluyla olduğundan dolayı zorlu bir süreç haline gelebilmektedir. Bazı büyük firmalar

milyonlarca görüntülerden oluşan veri kümeleri ile eğittikleri sınıflandırma doğruluk başarı oranları yüksek olan derin öğrenme modelleri (VGG16, AlexNet gibi) geliştirmektedirler. Derin öğrenme modellerinin bazıları 1000 sınıfa kadar nesne türlerini sınıflayabilmektedir. Zaman, maliyet gibi sebeplerden dolayı önceden eğitilmiş olan derin öğrenme modelleri (AlexNet, Vgg16 gibi) kullanılarak transfer öğrenme işlemleri yapılabilmektedir. Transfer öğrenme, kısaca bir veriden kazanılmış olan eğitim bilgisinin, başka bir veri kümesini sınıflandırmak amacı ile kullanılması olarak tanımlanabilmektedir.

Bu tez çalışmasında ayakkabı veri kümesi kullanılmaktadır. Bu veri kümesi ayrıntılı marka ve modellerine göre 107 sınıfa ayrılmış ayakkabı görüntülerini içermektedir. İnsan eliyle bu ayakkabı modellerinin türlerine ve türlerin markalarına göre ayrıştırılması veya sınıflandırılması çok zaman almakla birlikte yeni bir ayakkabı görüntüsünün hangi sınıfa dahil edileceğine karar vermek ise zorlu ve zaman alıcı bir süreç olabilmektedir. Bu gibi sorunları en aza indirmek amacı ile sınıflandırma hata oranı az ve tahmin zamanı açısından hızlı sonuçlar veren çözümler geliştirilmektedir. Bu geliştirilen çözümlerden biri de derin öğrenme modellerinden transfer öğrenme uygulamalarının yapılmasıdır.

Yapılan bu tez çalışması kapsamındaki deneysel çalışmalarda derin öğrenme modellerinden transfer öğrenme yöntemlerinden özellik çıkarımı ve ince ayar eğitimi kullanılmaktadır. Transfer öğrenme yöntemlerinden olan özellik çıkarımı yöntemi ile ayakkabı veri kümesindeki görüntülerin özellikleri AlexNet, InceptionV3 ve GoogLeNet derin öğrenme modellerinin tam bağlantılı katmanlarından çıkarılmakta ve çıkarılan bu özellikler daha sonra destek vektör makinesi ile sınıflandırılmaktadır. Bu şekilde yapılan deneysel testler ile sınıflandırma doğruluk başarı oranları ve çalışma süreleri hesaplanmaktadır. Diğer bir transfer öğrenme yöntemi olan ince ayar eğitim yöntemi ile derin öğrenme modellerinin eşikleyici (softmax) katmanında bulunan sınıf sayısı ayakkabı veri kümesinin sınıf sayısı ile değiştirilerek sınıflandırma doğruluk başarı oranları ve çalışma süreleri hesaplanmaktadır. Ayrıca sıfırdan tasarlanan konvolüsyonel sinir ağları ile ayakkabı veri kümesi eğitilerek deneysel

testler ile sınıflandırma doğruluk başarı oranları ölçülmektedir. Yapılan tüm bu deneysel çalışmalarda elde edilen genel sonuçlar kıyaslanmaktadır.

Bu tez çalışmasının ikinci bölümünde önceki çalışmalar ve literatür araştırmaları bahsedilmektedir. Üçüncü kısımda, materyal ve yöntemlerden; derin öğrenme, konvolüsyonel sinir ağları ve yapısı, transfer öğrenme yöntemleri, derin öğrenme modelleri ve destek vektör makinesinden hakkında bilgiler verilmektedir. Sonraki kısım olan araştırma bulguları ve tartışma bölümünde ayakkabı veri kümesi ile yapılan deneysel çalışmalar sonucunda elde edilen sonuçlar ve bulgular gösterilmektedir. Son bölümde ise genel sonuçlar ve öneriler verilmektedir.

2. ÖNCEKİ ÇALIŞMALAR

Derin öğrenme kullanılarak yapılan literatürdeki çalışmalar son yıllarda oldukça artmıştır. Salur ve Aydın (2018) yaptıkları bu çalışmada derin öğrenme ağlarından konvolüsyonel sinir ağı kullanılarak sosyal medya platformlarından biri olan twitter da atılan mesajların olumlu ve olumsuz olmak üzere iki sınıfa ayrılarak her bir sınıfta 13.000 mesaj olmak üzere duygu sınıflandırmaktadır. Yapılan çalışma diğer makine öğrenme yöntemleri ile karşılaştırılmış ve KSA'nın diğer yöntemlere göre daha başarılı sınıflandırma yaptığı gözlemlenmiştir.

Kızrak ve Bolat (2018) tarafından yapılan çalışmada kalabalık analizi ile ilgili bugüne kadar yapılmış olan literatürdeki çalışmalar incelenmektedir. Araştırmanın sonucunda kullanılan diğer yöntemlere kıyasla derin öğrenme ile yapılan çalışmaların daha başarılı sonuçlar verdiği gözlemlenmektedir.

Üzen ve ark. (2019) çalışmaları kapsamında bal arılarının sağlık durumlarını gözden geçirmek amacı ile beş farklı mimaride KSA'lar tasarlanarak hangi mimarinin daha iyi sonuç vereceği kıyaslamaktadır. Yapılan bu çalışma sonucunda çok katmanlı mimari tasarlamanın bir avantajı olmadığı önemli olan ideal katman sayısında tasarlamak olduğu gözlemlenmektedir.

Tavuk ve tavşan veri setleri kullanılarak bu hayvanlarda hastalıklara sebep olan eimeria parazit türlerinin mikroskobik görüntüleri tasarlanan konvolüsyonel sinir ağı ile sınıflandırılmaktadır ve oluşturulan web sitesi yardımı ile kullanıcılar tarafından yeni bir eimeria parazit görüntüsü yüklenerek parazit türünün hangi sınıfa ait olduğu tespit edilmektedir. Yapılan bu çalışmada derin öğrenme mimarisi ile sınıflandırma başarısı diğer makine öğrenme yöntemlerine göre daha iyi sonuç verdiği gözlemlenmiştir.(Yılmaz, M., 2017)

Uzaktan algılamada hedef tespiti ve sınıflandırma yapmak için farklı sayılardaki katmanlardan oluşan konvolüsyonel sinir ağları test edilerek modellerin en uygun parametre değerleri tespit edilmektedir. Daha sonra hipersektral ve lidar görüntü verileri bu modellerle sınıflandırılmaktadır. (Mutlu, H. E.,2018)

Yapılan diğer bir çalışmada web sayfalarının sınıflandırılması amacı ile oluşturulan derin öğrenme mimarileri eğitilip test edilmektedir ve daha önceden bu konu ile ilgili olarak diğer makine öğrenme yöntemleri kullanılarak yapılan çalışmalar ile karşılaştırıldığında sınıflandırma başarısının daha yüksek olduğu tespit edilmektedir. (Kurt, M. S., 2018)

Derin öğrenme yöntemlerinin donanımsal ihtiyaçlarından dolayı birçok araştırmacı transfer öğrenme yöntemlerine yönelmektedir. Gündüz ve Cedimoğlu (2019) tarafından yapılan bu makalede derin öğrenme modellerinden AlexNet ve VGG16 kullanılarak cinsiyet tahmini yapılmaya çalışılmaktadır. Yeni geliştirdikleri başka bir KSA ile bu modellerin başarıları kıyaslanmaktadır ve sonuç olarak VGG16 modeli ile yapılan deneysel çalışmanın başarısının daha yüksek olduğu görülmüştür.

Şen ve Keleş (2019), yaptıkları çalışma ile hava fotoğraflarını kullanarak sahne sınıflandırması yapmaktadırlar. Sınıflandırma yapmak için ResNet50 derin öğrenme modelinden faydalanmaktadırlar.

Hiperspektral görüntüleme ile buğday görüntüleri derin öğrenme yöntemleri ile sınıflandırılmaktadır. Bu yöntemlerden birincisi AlexNet derin öğrenme modelinin fc6 ve fc7 katmanlarından çıkarılan özellikler buğdayların sınıflarını belirlemek amacı ile destek vektör makinesi ile sınıflandırılmaktadır. Doğrusal destek vektör makinesi sınıflandırıcısı ile fc6 özelliklerinde %99,9695 ve fc7 özelliklerinde %99,9637'lik ortalama doğruluk oranları elde edilmektedir. İkinci yöntem olarak derin öğrenmeye

dayanan, VGG16, VGG19 ve GoogLeNet mimarilerinden belirlenen güçlü özellikler alınarak, konvolüsyon katmanlarında kullanılan ağırlıkların ayırt edici bilgileri ile kullanılarak eğitilmektedir. Bu tez çalışmasında bu yöntemlerden ayrı olarak çeşitli yöntemlerde kullanılarak sınıflandırma doğruluk oranları karşılaştırılmaktadır. (Demirez Örs, D. Z., 2018)

Gemi görüntülerinden oluşan MARVEL veri kümesi AlexNet, VGGNet ve ResNet mimarilerinden transfer öğrenme yapılarak, bu mimarilerin sınıflandırma başarıları kıyaslanmaktadır. Bu çalışma da çeşitli transfer öğrenme teknikleri ile deneysel çalışmalar yapılmaktadır. En yüksek başarı VGG-16 mimarisinden transfer öğrenme yapılarak elde edilmektedir. (Gürkaynak, C.D., 2018)

Doğan ve Türkoğlu (2018) yaptığı çalışmada yaprak görüntülerinin sınıflandırılması için derin öğrenme mimarilerinden AlexNet, Vgg16, Vgg19, ResNet50, GoogLeNet mimarilerini kullanılarak sınıflandırma başarılarını değerlendirmiştir. Derin öğrenme büyük veri setlerinde daha iyi sonuçlar verdiği için 32 sınıftan ve 1900 görüntüden oluşan UCI yaprak veri kümesi yansıma ve tersleme gibi işlemler yapılarak görüntü sayısı 7628 yapılmıştır. Yapılan deneysel çalışmalarda görüntülerin %80 i eğitim %20 si test verisi olarak kullanılmıştır. Sonuç olarak en yüksek sınıflandırma doğruluk oranı %99,72 ile AlexNet derin öğrenme modelinden elde edilmiştir.

Ulu ve Ekenel (2016) yaptıkları çalışmada kişiyi yeniden tanımlama problemi üzerinde bir yöntem geliştirmişlerdir. Bu yöntem de öncelikle farklı kameralardan gelen kişi üzerinde önişlem yapılarak görüntülerin arka planı silinip kişi baş, gövde ve bacaklar olmak üzere 3 parçaya ayrılıp ince ayar işlemi için hazır hale getirilmiştir. AlexNet derin öğrenme modeli kullanılarak her bir parçadan oluşan veri kümeleri (AlexNet-baş gibi) ayrı ayrı eğitilmiştir. Böylelikle 6 tane model elde edilmiştir. Daha sonra verilen bir kişi resminden bu üç modelin 7. Katmanından öznitelikleri çıkarılmaktadır. Farklı kameralardan gelen iki farklı kişinin görüntüsünün

karşılaştırılması içinde kosinüs benzerlik uzaklığı kullanılmıştır. Bu yöntem diğer daha önceki yapılan yöntemlerle karşılaştırıldığı zaman diğer yöntemlerden daha başarılı sonuç verdiği gözlemlenmiştir.

Asefisaray ve ark. (2018), yaptıkları bu çalışmada otomatik konuşma tanıma sistemlerinde transfer öğrenme yöntemi kullanmışlardır. Öncelikle kaynak modelin eğitimi için çağrı merkezi telefon kayıtları kullanılarak veri kümesi oluşturulup eğitilmiştir. Sonra TBMM oturum kayıtlarından toplanan veriler hedef kaynak olarak kullanılarak oluşturulan model üzerinden transfer öğrenme yapılarak eğitilmektedir. Derin sinir ağı modeli farklı hedef veri boyutu, transfer katman sayıları ve öznitelik çıkarıcılar üzerinde eğitilerek konuşma tanıma başarıları karşılaştırılmıştır.

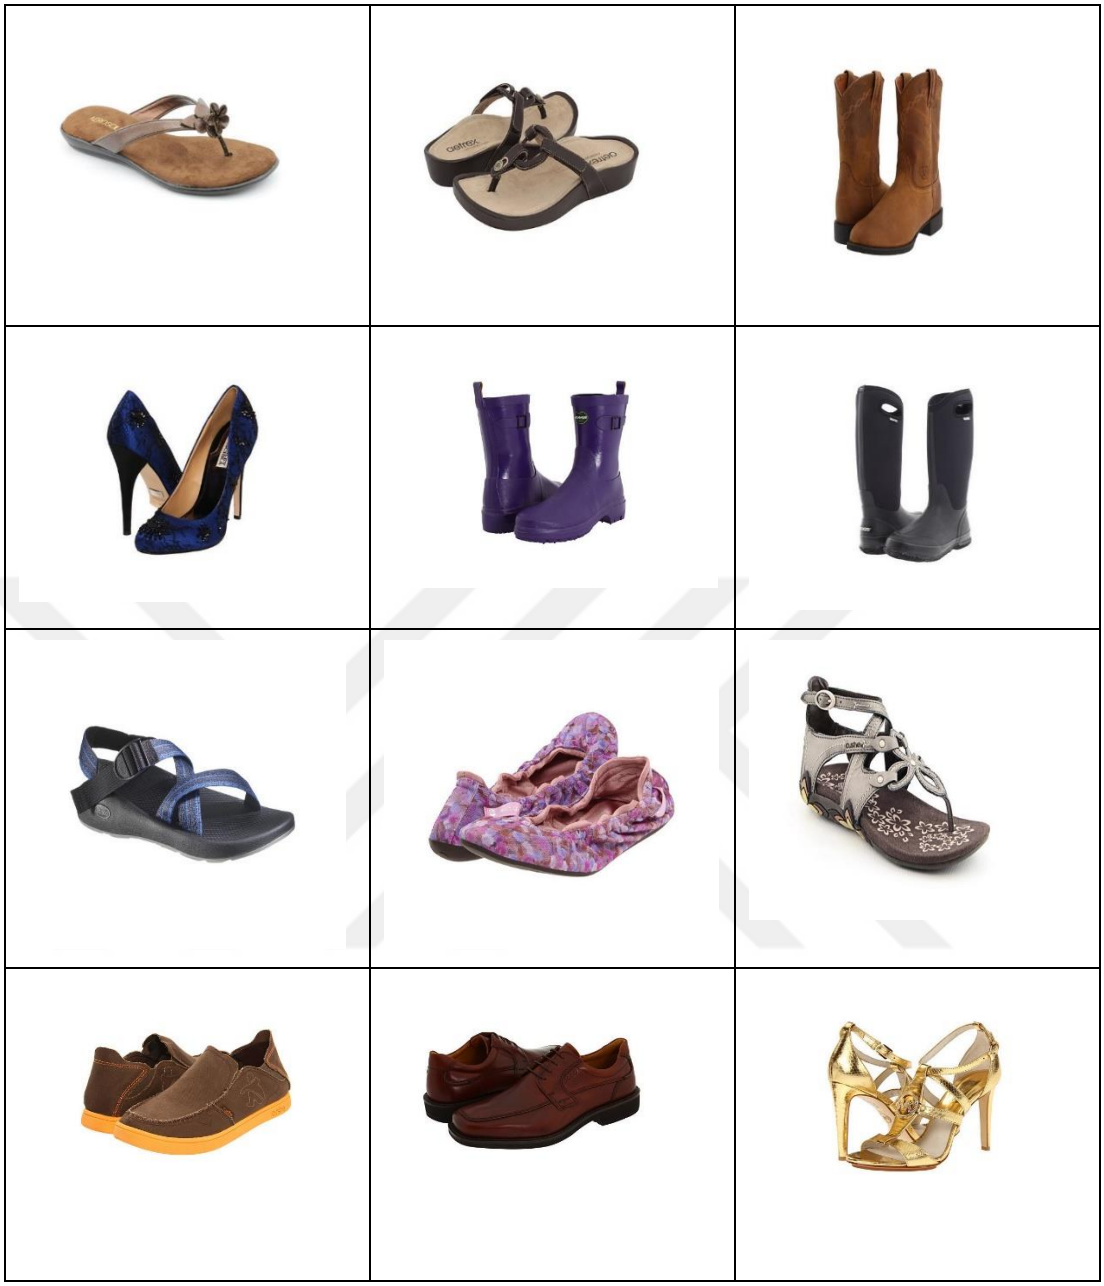
Ayakkabı veri kümesini sınıflandırmak amacı ile derin öğrenme yöntemlerinden faydalanılmaktadır. Korzh ve ark. (2018) ayakkabı veri kümesi ve farklı iki veri kümesi daha kullanarak geliştirdikleri derin öğrenme modellerinin sınıflandırma başarısını ölçmektedirler. İnce ayar transfer öğrenme yöntemi kullanarak AlexNet, VGG19 ve GoogLeNet derin öğrenme modellerini birleştirip hibrit hale getirerek sınıflandırma başarısını artırmaya çalışmaktadırlar.

Iliukovich-Strakovskaia ve ark. (2016) geliştirdikleri sınıflandırma modeli ile boyut azaltma temelli bir yaklaşım kullanılarak özellik çıkarımı ve önceden eğitilmiş derin öğrenme modelinden özellik çıkarımı yöntemi uygulanarak ayakkabı görüntülerinin özellikleri elde edilmektedir. Bu işlemler sonrasında elde edilen bu özellikler birleştirilmektedir. Daha sonra rastgele orman sınıflandırıcısı (random forest classifier) ile sınıflandırılarak doğruluk başarı oranı hesaplanmaktadır.

3. MATERYAL ve YÖNTEM

3. 1 Veri Kümesi

Tez çalışmasında kullanılan veri kümesi Yahoo araştırma laboratuvarı (2013) tarafından oluşturulan ayakkabı veri kümesidir. İçeriği 5250 ayakkabı görüntüsünden oluşmaktadır. Ayakkabı görüntüleri marka ve modellerine göre 107 ayakkabı türüne ayrılarak sınıflandırılmıştır. Aşağıdaki şekilde farklı ayakkabı sınıflarından alınan bazı örnek görüntüler gösterilmektedir. Şekilde de görüleceği üzere birbirine benzer pek çok ayakkabı görüntüsü farklı sınıflarda yer almaktadır. Sınıf sayısının fazlalığı farklı sınıflardaki örneklerin birbirine yakınlığı gibi faktörler sınıflandırma problemini daha da zorlaştırmaktadır.



Şekil 3.1. Ayakkabı veri kümesindeki bazı ayakkabı türlerine ait örnek görüntüler

3.2 Derin Öğrenme

Derin öğrenme insanların öğrenme sistemleri örnek alınarak geliştirilmiş, çok sayıda gizli katman ve nöronlardan oluşan bir makine öğrenme yöntemidir. Zamanla gelişen donanımsal özelliklerinde katkısı ile (özellikle grafik işlemcilerinin hesaplamaya katılması) büyük boyutlu veri kümelerinin işlenmesi için derin öğrenme

yöntemi kullanılmaktadır. Derin öğrenme ile görüntülerdeki nesneler çok katmanlı sinir ağları ile eğitilerek sınıflandırılmaktadır. Görüntülere ait özellikleri çıkarmak için başka yöntemlere ihtiyaç duymaması derin öğrenme ağlarının özelliklerindendir. Derin öğrenme ağları hangi bilgiyi kullanması gerektiğine kendisi karar verebildiği için diğer yöntemlere kıyasla daha başarılı sonuçlar vermektedir (Kızrak, M. A. ve Bolat, B., 2018).

Günümüzde geliştirilen derin öğrenme ağları sayesinde görüntü içerisindeki nesneler sadece tespit edilmekle kalmayıp, tespit edilen nesneler arasındaki ilişkiler de yorumlanabilmektedir. Şekil 3.2'de verilen resimler sırasıyla derin öğrenme ağları ile "siyah-beyaz köpek bar üzerinden atlıyor" ve "bir ağaç dalına tünemiş kuş " olarak yorumlanmıştır.

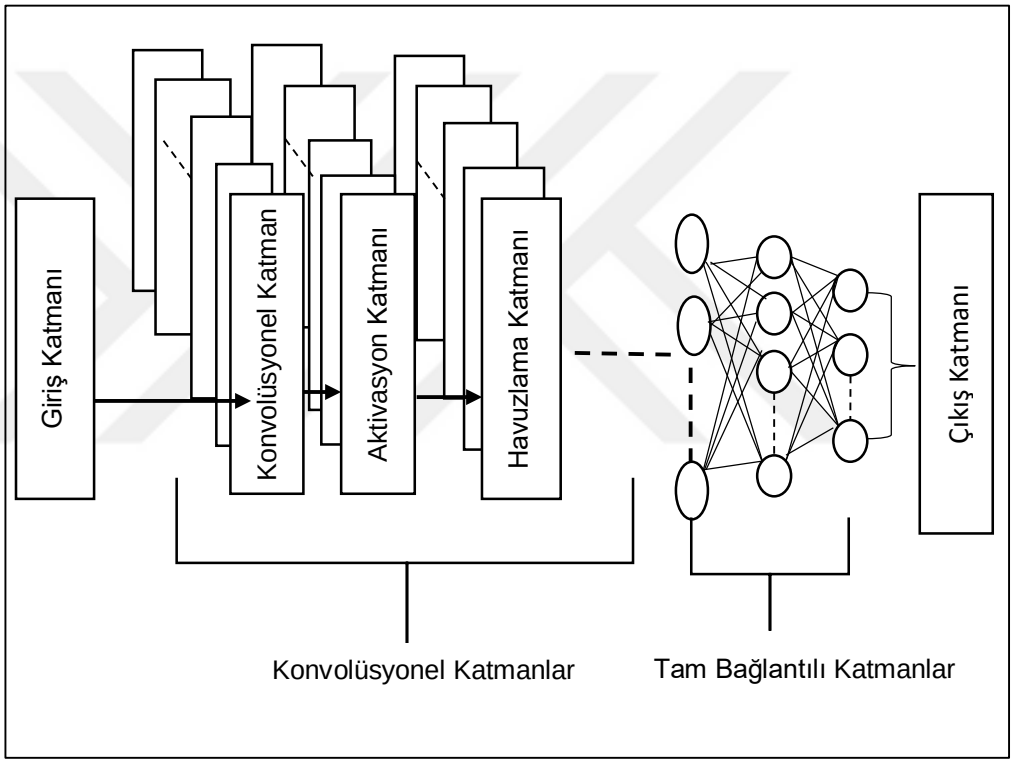


Şekil 3.2. Derin öğrenme ile yorumlanmış görüntüler (Karpathy,A. ve Fei Fei,L., 2016)

Derin öğrenme yöntemleri pek çok alanda kullanılmaktadır. Görüntü işleme, konuşma tanıma, yüz tanıma, video analizi, metin işleme, savunma ve güvenlik sektörü bu alanlara verilebilecek örneklerden bazılarıdır. Yapılan çalışmalara uygun olarak çeşitli derin öğrenme yöntemleri geliştirilmektedir. Bunlardan görüntü sınıflandırmak için en yaygın olarak kullanılan yöntem konvolüsyonel sinir ağları yöntemidir.

3.2.1 Konvolüsyonel Sinir Ağları

Görüntü sınıflandırma işlemlerinde sıkça kullanılan KSA'lar genel olarak birbiriyle bağlantılı konvolüsyonel katman, aktivasyon katmanı, havuzlama katmanı ve tam bağlantılı katmanların bir araya gelmesiyle tasarlanmaktadır (Üzen, H. ve ark., 2019). Kullanılacak olan katman sayıları uygulamaya göre farklılık gösterebilmektedir. Şekil 3.3'de konvolüsyonel sinir ağının yapısı gösterilmektedir.

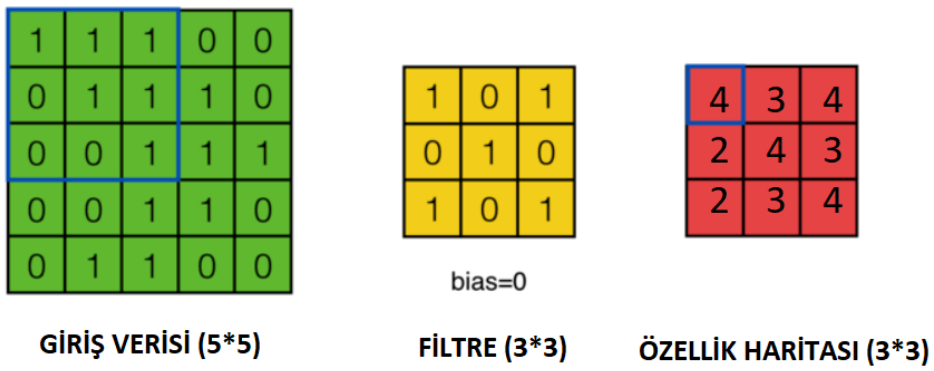


Şekil 3.3. Konvolüsyonel sinir ağı yapısı

Verilen görüntüdeki pikseller matris şeklinde girdi katmanına verilmektedir. Eğer görüntü renkli ise kanal sayısı 3 olarak belirlenmekte ve renk değerleri 0-255 arasında piksel değerleriyle temsil edilmektedir.

Girdi katmanından alınan görüntü konvolüsyonel katmana iletilmektedir. Konvolüsyonel katmanda görüntüye çeşitli filtreler uygulanarak görüntü içerisindeki

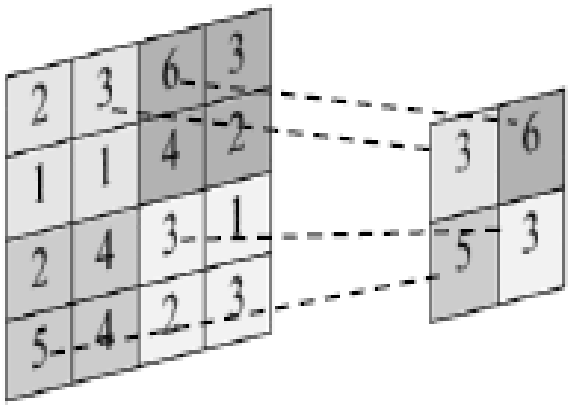
nesnelere ait özellikler bulunmaya çalışılmaktadır ve kullanılan filtreler ağın performansını doğrudan etkilemektedir (Pang, Y. ve ark., 2017). İnsan olarak da bir görüntüye baktığımız zaman içerisindeki nesneleri tanımlayabilmek ya da sınıflandırabilmek için o nesneleri benzersiz yapan özellikleri bilmemiz gerekmektedir. Nesnelere ait kenarların tespiti için yatay ve dikey filtreler uygulanarak görüntü içerisindeki yüksek frekanslı pikseller bulunmaktadır. Farklı kenar bulma filtreleri ile (açısal kenarlar gibi) görüntüye ait öznitelikler hesaplanmaktadır. Konvolüsyonel katmanda görüntüye uygulanan filtreler kaydırma işlemi (stride) ile tüm görüntüde gezdirilmektedir. Kaydırma işlemi sonrasında görüntünün çıkış boyutu değişebilmektedir. Giriş ve çıkış görüntüsü arasında filtre uygulamaktan dolayı piksel eksikliği olabilmektedir. Giriş ve çıkış matrislerinin farklı boyutta olması istenmiyorsa piksel ekleme işlemi (padding) uygulanabilmektedir. Şekil 3.4'de konvolüsyonel katmanda kullanılan filtrelerin görüntü üzerinde gezdirilmesi gösterilmektedir.



Şekil 3.4. Konvolüsyonel katmanda filtrelerin kullanılma örneği (Kurt, M.S., 2018)

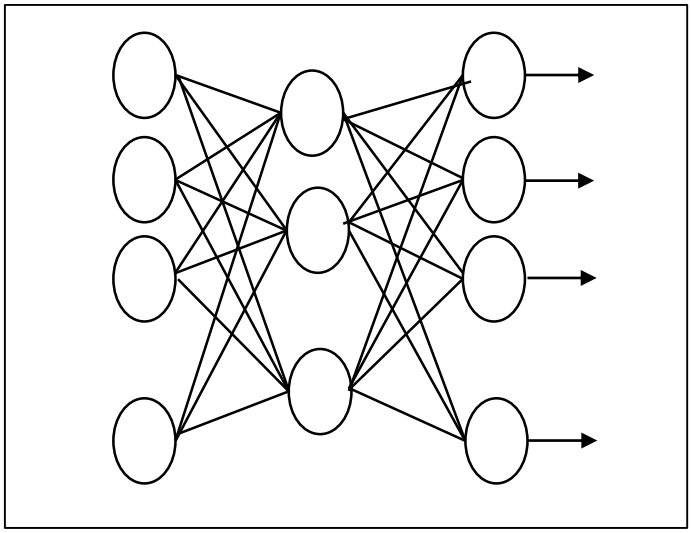
ReLu konvolüsyonel katmandan sonra genel olarak kullanılmakta olan aktivasyon fonksiyonudur. ReLu ile konvolüsyonel katmanda elde edilen matrisler içerisindeki negatif değerli piksellerin hesaplamaya alınmaması için bu değerlerin sıfırlanması amacıyla kullanılmaktadır (Nair, V. ve Hinton, G. E., 2010). Elde edilen matris daha sonra havuzlama katmanına iletilmektedir.

Havuzlama (pooling) katmanı ile konvolüsyonel katmandan gelen matrisin yükseklik ve genişliği azaltılarak hesaplama karmaşıklığı azaltılmaya çalışılmaktadır (Hinton, G. ve ark., 2012). Azaltma işlemi için genel olarak maksimum havuzlama kullanılmaktadır. Maksimum havuzlama yöntemi ile seçilen havuzlama boyutu içerisindeki en yüksek değerli olan piksel alınmaktadır. Yani aynı görüntünün daha küçük boyutlu hali elde edilmektedir. Şekil 3.5'de havuzlama katmanına örnek gösterilmektedir.



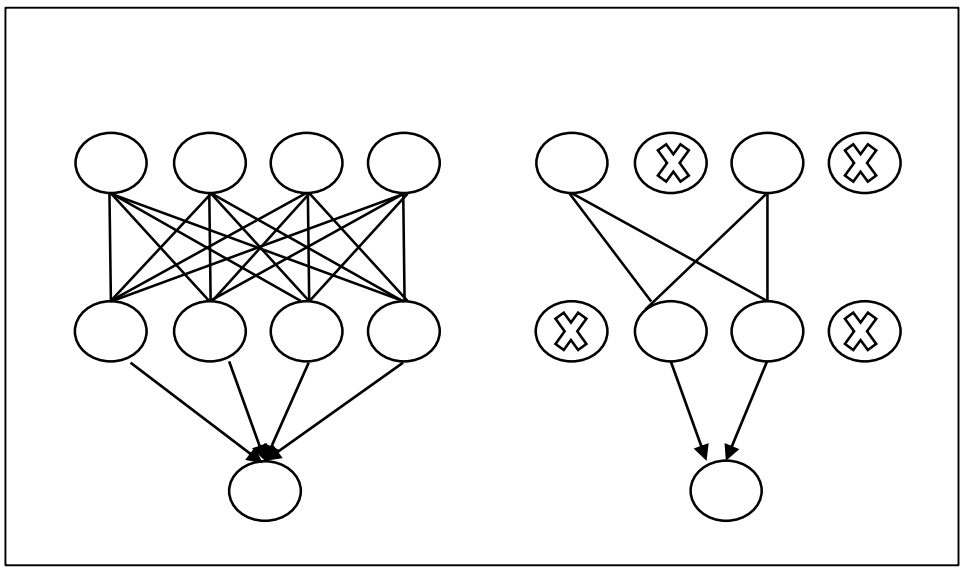
Şekil 3.5. Havuzlama katmanı (Zeiler, M. D., ve Fergus, R., 2013)

Tam bağlantılı katmandaki tüm nöronlar kendinden önceki katmandaki aktivasyonların hepsine tam bağlıdır. Önceki katmana bağlı olarak tam bağlantılı katman ile nesneyi belirleyen özelliğin hangi sınıfa ait olduğu belirlenmektedir (Doğan, F. Ve Türkoğlu, İ., 2019). Tam bağlantılı katmanın bir sınıfla ilişkilendirmek için yüksek seviyeli özellik sahibi olan değerlere bakılarak hangi sınıfa ait olduğu tespit edilmektedir (Lin, M. ve ark., 2013). Şekil 3.6'de tam bağlantılı katman yapısı gösterilmektedir.



Şekil 3.6. Tam bağlantılı katman

Kaçınma (dropout) katmanı ile aşırı öğrenme olarak da adlandırılan ezberlemeyi engellemek amacı ile geliştirilmiştir. Ezberlemeden öğrenmenin gerçekleşebilmesi için rastgele bazı nöronlar çıkarılmaktadır (Hinton, G. ve ark., 2012; Srivastava, N. ve ark., 2014). Şekil 3.7'de kaçınma uygulanmış sinir ağı yapısı gösterilmektedir.



Şekil 3.7. Sol tarafta kaçınma uygulanmamış yapay sinir ağı (YSA), sağ tarafta kaçınma uygulanmış YSA gösterilmektedir.

Sınıflandırma katmanı ile her bir sınıfı temsil eden öğe sayısı kadar sonuç üretilmektedir. Genel olarak eşikleyici (softmax) katmanı sınıflandırma katmanı olarak kullanılmaktadır (Ciresan, D. ve ark., 2011). Eşikleyici katmanı ile olasılıksal bir girdi verisinin bir sınıfa dahil olma durumunu belirlemektedir ve hangi sınıfa daha yakın ise ona göre değer üretmektedir. Çapraz entropi yöntemi kullanarak her bir sınıf için olasılıksal hesaplama yaparak olasılık değerlerini çıkarmaktadır (Tang, Y., 2013).

3.2.2 Transfer Öğrenme

Derin öğrenme ağlarının büyük veri kümeleri ile daha iyi sonuçlar verdiği yapılan çalışmalarda da görülmektedir. Ne kadar çok veri olursa öğrenme oranı o kadar çok artmaktadır. Hesaplama yapmak için kullanılan donanımsal özelliklerin gelişmesi ile birlikte derin öğrenme kullanımı yaygın hale gelmektedir. Derin öğrenme de kullanılan yapay sinir ağlarındaki gizli katman sayılarının artırılması ile derinleştirilen ağlar daha büyük bellek ihtiyacı duymaktadır ve aynı zamanda daha hızlı bilgisayarların kullanılması gerekmektedir (İnik, Ö. ve Ülker, E., 2017). Bu tez çalışmasında AlexNet ile yapılan uygulamalarda görüntülerin giriş boyutu 227x227x3 olarak alınmakta ve veri kümesi 5250 görüntüden oluşmaktadır. Bu durumda 227x227x3x5250 baytlık belleğe ihtiyaç duyulmaktadır. ImageNet gibi milyonlarca görüntüden oluşan veri setleri kullanılırsa bellek ihtiyacı daha da artmaktadır. Bir başka donanımsal gereklilikte geriye yayılım algoritması yapılırken paralel işlemcilerin kullanılmasıdır. Bunun içinde genellikle GİÜ'lar tercih edilmektedir. Bu bahsedilen donanımsal gereklilikler büyük maliyetlere sebep olabilmektedir (İnik, Ö. ve Ülker, E., 2017). Ayrıca sıfırdan tasarlanacak olan ağdaki parametrelerin doğru bir şekilde belirlenmesi de deneme yolu ile olacağından dolayı zaman kaybına neden olmaktadır.

Google gibi bazı büyük firmaların geliştirmekte olduğu derin öğrenme modelleri (GoogLeNet, InceptionV2, InceptionV3 gibi) ile transfer öğrenme yöntemleri kullanılarak veri kümelerinin sınıflandırmasını yapmak hesaplama zamanı ve donanım

maliyeti açısından avantaj sağlamaktadır. Transfer öğrenmeyi önceden eğitilmiş derin öğrenme modellerinin öğrenilmiş ağırlık değerlerini farklı veri kümelerinin sınıflandırma işlemi için başka bir derin öğrenme ağına aktarılması olarak tanımlayabiliriz. Kısaca ağı sıfırdan eğitmek yerine önceden öğrenilmiş ağırlıklarla eğitilmesi olarak da tanımlanabilmektedir (Kın, Z. B., 2019). Transfer öğrenme yapılırken çeşitli yöntemler kullanılmaktadır. Transfer öğrenme yöntemlerinden özellik çıkarımı yöntemi kullanılarak derin öğrenme modelleri ile eğitilen veri kümesindeki görüntülerin özellikleri modellerin tam bağlantılı katmanlarından (FC6, FC7 gibi) çıkarılmaktadır. Daha sonra elde edilen bu özellikler diğer makine öğrenme yöntemleri (DVM, K-en yakın komşuluk gibi) ile sınıflandırılarak doğruluk başarı oranları hesaplanmaktadır. Diğer transfer öğrenme yöntemi ince ayar yöntemidir. Bu yöntem ile önceden eğitilmiş derin öğrenme modellerinin eşikleyici (softmax) katmanındaki sınıf sayısı kullanılacak olan veri kümesindeki sınıf sayısı ile değiştirilip eğitilerek sınıflandırma doğruluk başarı oranı hesaplanmaktadır.

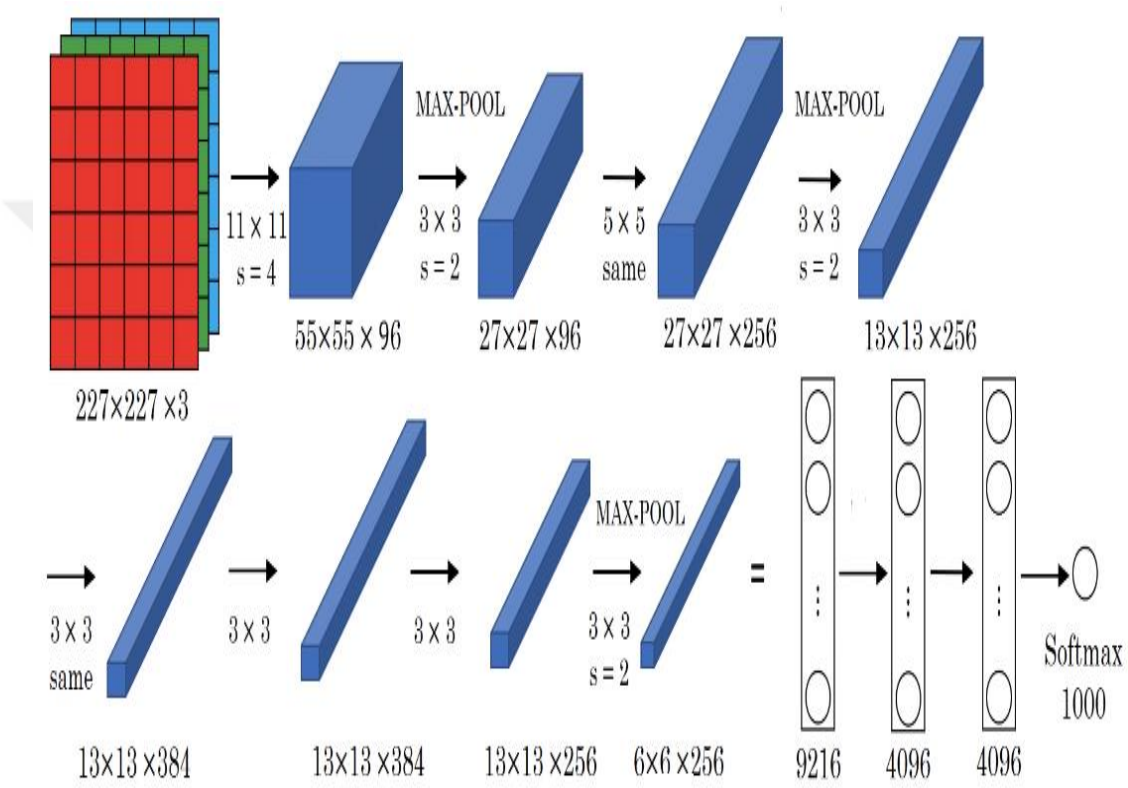
3.3 Önceden Eğitilmiş Derin Öğrenme Modelleri

Önceden eğitilmiş derin öğrenme modelleri ile transfer öğrenme yöntemleri kullanılarak ayakkabı veri kümesinin sınıflandırma doğruluk başarı oranları hesaplanmaktadır. Bu çalışmada derin öğrenme modellerinden AlexNet, Inceptionv3 ve GoogLeNet kullanılmaktadır.

3.3.1 AlexNet

Transfer öğrenme uygulamalarında yaygın olarak kullanılan Alex Krizhevsky ve arkadaşları tarafından 2012 yılında geliştirilmiştir ve AlexNet in mimari yapısı şekil 3.8'de gösterilmektedir (Krizhevsky, A. ve ark., 2012). ImageNet veri tabanı üzerindeki 1 milyondan fazla görüntü ve 1000 farklı sınıfı (hayvan, bitki gibi) eğitilerek oluşturulmuş bir derin öğrenme modelidir. Görüntü girdi boyutları 227x227x3 olarak verilmektedir. Toplamda 25 katmandan oluşmaktadır ve yaklaşık

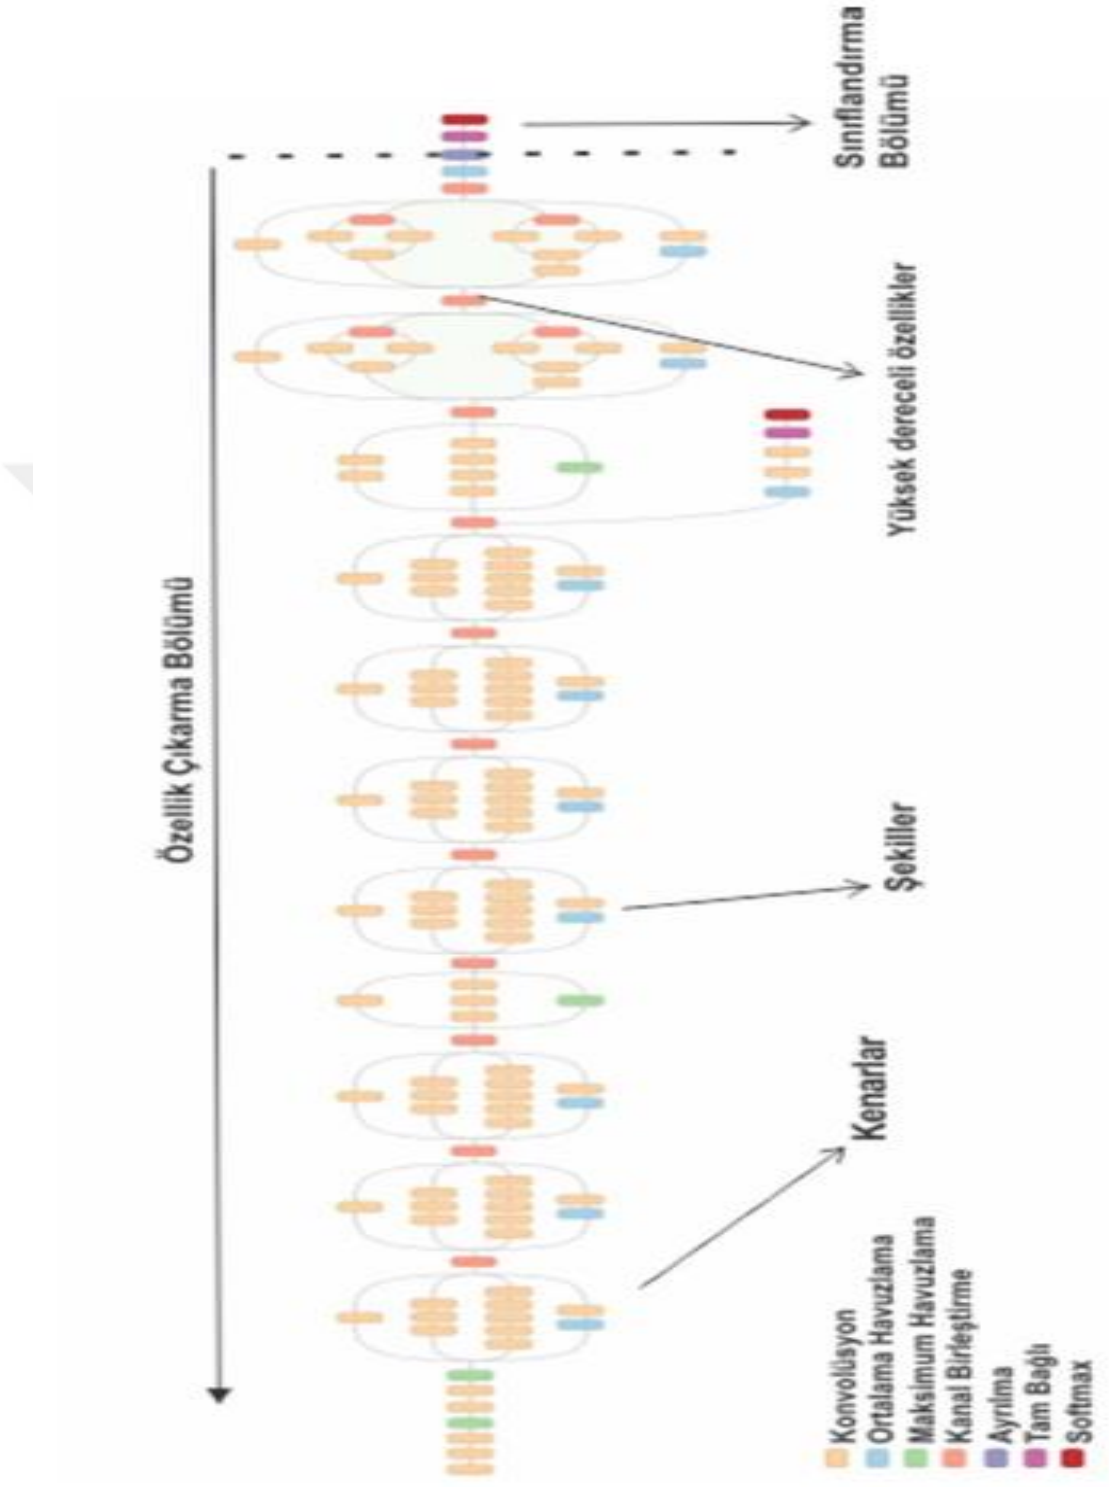
olarak 60 milyon parametre hesaplanmıştır. 5 konvolüsyonel katman, 7 ReLu aktivasyon fonksiyon katmanı, 3 havuzlama katmanı ve 3 tam bağlantılı katman kullanılarak oluşturulmuştur. AlexNet den transfer öğrenme yöntemleri kullanılarak önceden öğrenilmiş parametreler sayesinde daha küçük boyutlu veri kümeleri daha iyi sınıflandırılabilmektedir.



Şekil 3.8. AlexNet derin öğrenme modelinin mimari yapısı (3)

3.3.2 InceptionV3

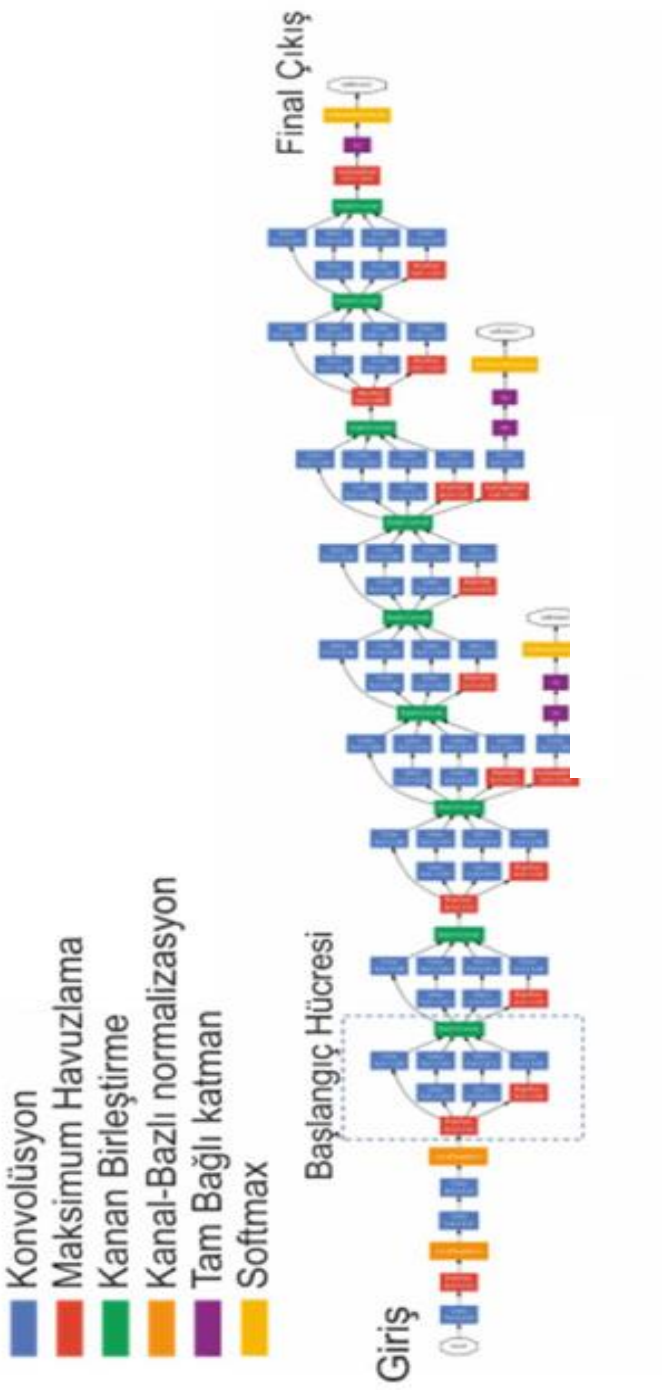
Google tarafından geliştirilen InceptionV3 derin öğrenme modeli ImageNet veri kümesini kullanılarak eğitilmiş bir derin öğrenme ağıdır (Szegedy, C. ve ark., 2016). 48 katman derinliğe sahip bu model görüntü girdi boyutlarını 299x299x3 şeklinde almaktadır. Şekil 3.9'da InceptionV3 modelinin yapısı gösterilmektedir.



Şekil 3.9. InceptinV3 derin öğrenme modelinin yapısı (Tapas, A., 2016)

3.3.3 GoogLeNet

GoogLeNet 2015 yılında Christian Szegedy ve arkadaşları tarafından ImageNet veri kümesi (Deng, J ve ark., 2009) kullanılarak hazırlanmış bir derin öğrenme ağıdır ve şekil 3.10'da GoogLeNet'in mimari yapısı gösterilmektedir. Giriş görüntüleri 224x224x3 olarak verilmekte ve 22 katman derinlikten oluşmaktadır. GoogLeNet mimari olarak ardışık olarak sıralanmış konvolüsyon ve havuzlama katmanları yerine paralel olarak birbirine bağlanmış modüler yapılardan oluşmaktadır. Bellek kullanımını düşürmek, hesaplama maliyetlerinin azaltılmaya çalışılması ve ezberleme olasılığını indirgemek amacı ile paralel bağlı modüler yapı kullanılmaktadır (İnik, Ö. ve Ülker, E., 2017).



Şekil 3.10. GoogLeNet mimari yapısı (Szegedy, C. ve ark., 2015)

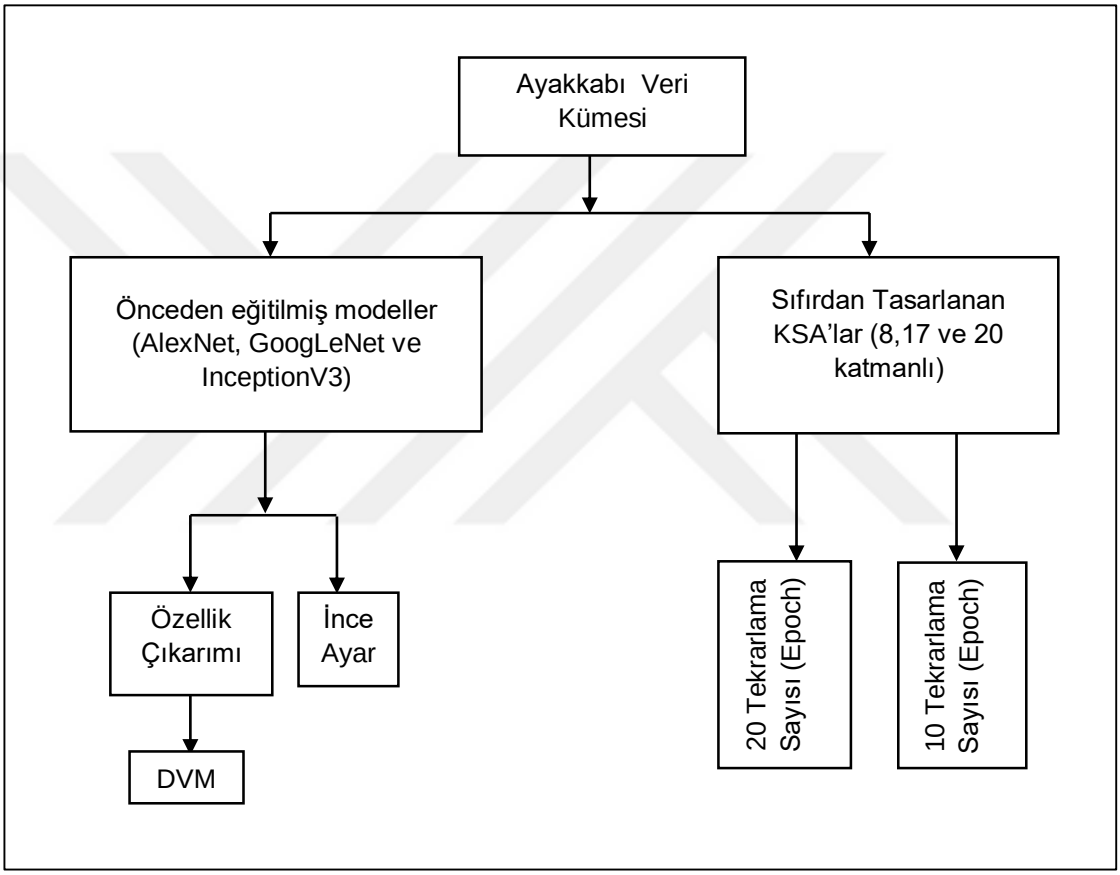
3.4 DVM (Destek Vektör Makinesi)

DVM sınıflandırma probleminin çözümü için geliştirilmiş bir makine öğrenme yöntemidir (Ayhan, S. ve Erdoğmuş, Ş., 2014). Cortes ve Vapnik tarafından 1995 yılında geliştirilen destek vektör makinesi yöntemi temel olarak istatiksel öğrenmeye dayanmaktadır (Cortes, C. ve Vapnik, V., 1995). Hiper düzlemler kullanılarak iki sınıfa ait veriler birbirinden en uygun bir biçimde ayrılmaya çalışılmaktadır. Belleği verimli bir şekilde kullanmak amacı ile karar fonksiyonunda eğitim noktaları verilmektedir. Doğrusal ve doğrusal olmayan DVM olmak üzere ikiye ayrılmaktadır.

Doğrusal DVM ile veri sınıflandırılırken hiper düzlemin sınıflara ait sınır çizgilerine en yakın uzaklıkta olması gerekmektedir. Doğrusal olmayan DVM doğrusal olmayan veri kümelerinde kullanılmaktadır. Çekirdek yöntem adı verilen bir yöntem ile sınıflar birbirinden ayrılmaya çalışılmaktadır.

4. ARAŞTIRMA BULGULARI VE TARTIŞMA

Bu tez çalışması kapsamında yapılan deneysel çalışmalar şekil 4.1 de gösterilmektedir. Deneysel çalışmalarda intel core i5 işlemcisi, 8GB Ram belleği ve 4GB kapasiteli NVIDIA GeForce MX150 grafik işlemcili ekran kartı bulunmakta olan bilgisayar kullanılmaktadır.



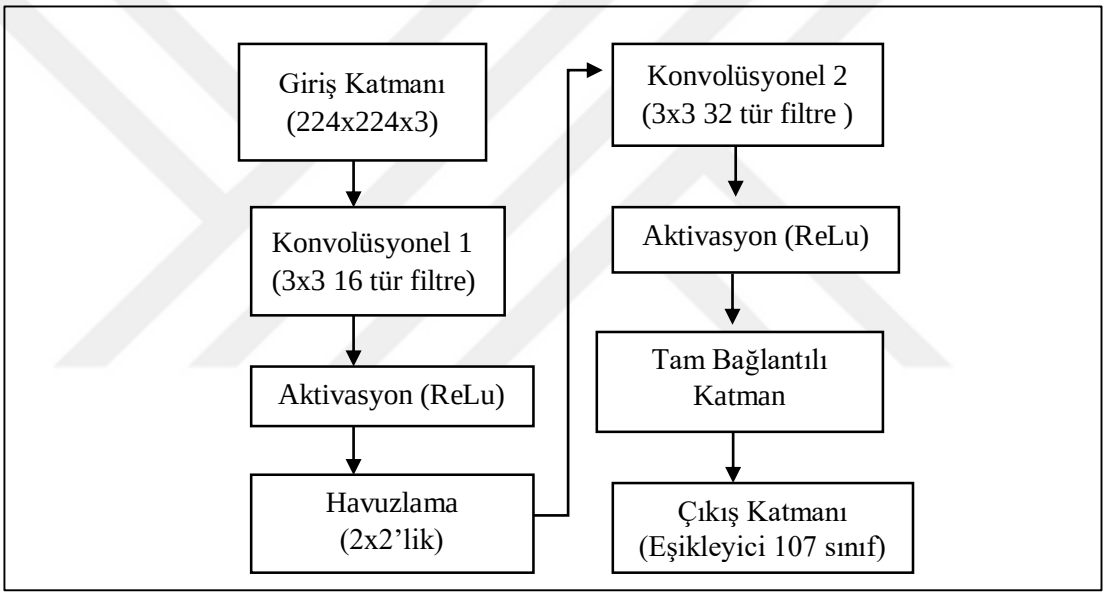
Şekil 4.1 Ayakkabı veri kümesi ile yapılan deneysel çalışmaların ana şeması

4.1 Konvolüsyonel Sinir Ağı ile Yapılan Deneysel Çalışmalar

Sıfırdan tasarlanan 3 farklı KSA ile ayakkabı veri kümesini sınıflandırma doğruluk oranları hesaplanmaktadır. Veri kümesindeki görüntüler %90 eğitim ve %10 test verisi olarak ayrılmaktadır. 10 katlı çapraz doğrulama yöntemi ile sınıflandırma doğruluk başarı oranları bulunmaktadır. Her bir KSA 20 tekrarlama sayısı (epoch) ve

10 tekrarlama sayısı (epoch) ile hesaplanarak en iyi başarı elde edilmeye çalışılmaktadır.

İlk olarak tasarlanan KSA' nın konvolüsyonel katman sayısı 2, ReLu katmanı 2 ve havuzlama katmanı 1 olmak üzere girdi, tam bağlantılı katman ve eşikleyici sınıflandırma katmanı ile birlikte toplam 8 katmandan oluşmaktadır. Tasarlanan KSA mimarisi şekil 4.2'de verilmektedir. 8 katmanlı olarak tasarlanan bu KSA ile yapılan deneysel çalışmaların sonuçları sırasıyla tablo 4.1 ve tablo 4.2 de gösterilmektedir.



Şekil 4.2. 8 katmanlı KSA mimarisi

Tablo 4.1. 8 katmanlı KSA ve 10 tekrarlama sayısı ile yapılan deneysel çalışma

KSA (8 Katmanlı)	Eğitim (%)	Test (%)	Süre (Sn.)	Tekrarlama Sayısı (Epoch)
1	61.71	44.93	1368.81	10
2	80.02	50.77	1412.97	10
3	65.81	41.35	1392.81	10
4	83.01	49.72	1393.85	10
5	63.37	41.95	1388.99	10
6	77.77	52.77	1521.57	10
7	81.85	46.46	1430.37	10
8	66.98	44.19	1429.87	10
9	61.63	41.12	1505.18	10
10	72.52	42.26	1493.60	10
Ortalama/SS	71.47/ 0.086	45.55/ 0.042	1433.80/ 54.102	10

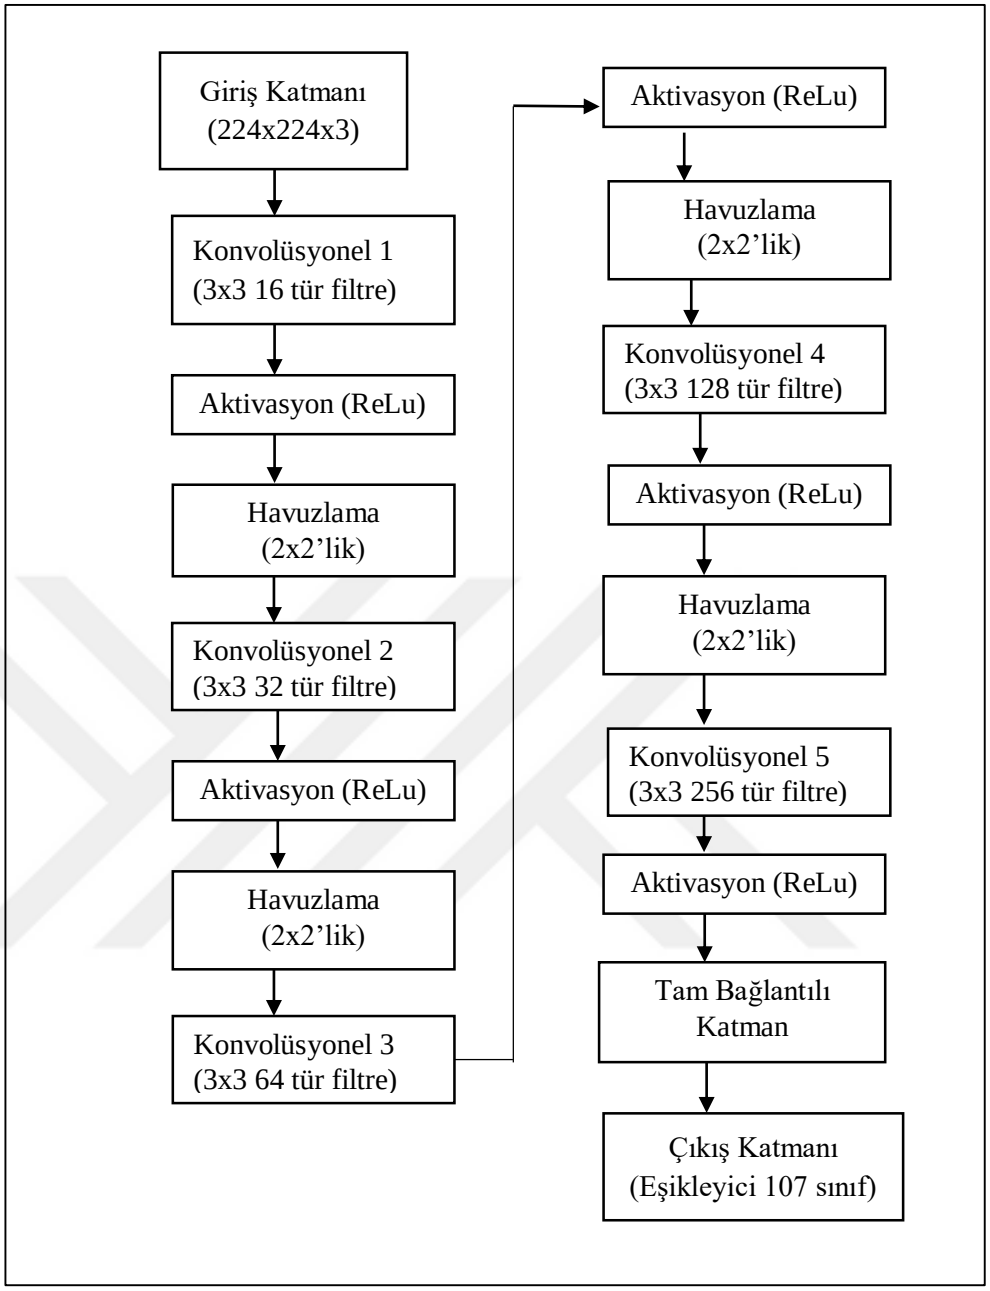
Tablo 4.1'de görüleceği üzere sıfırdan tasarlanan 8 katmanlı KSA ve 10 tekrarlama sayısı ile yapılan deneysel çalışma sonucunda eğitim yaklaşık olarak ortalama %72 başarı ile yapılmaktadır. Test verileri elde edilen sınıflandırma başarısı yaklaşık olarak ortalama %46 olarak hesaplanmaktadır. Bu deneysel çalışmanın çalışma süresi her bir deney için ortalama 1433.80 saniye sürmektedir. En başarılı sınıflandırma başarısı bu deneysel çalışmada yaklaşık %53 ile 6. testte elde edilmektedir.

Tablo 4.2. 8 katmanlı KSA ve 20 tekrarlama sayısından oluşan deneysel çalışma sonucu

KSA (8 Katmanlı)	Eğitim (%)	Test (%)	Süre (Sn.)	Tekrarlama Sayısı (Epoch)
1	73.18	47.61	2649.74	20
2	83.38	51.73	2616.48	20
3	81.46	46.15	2570.69	20
4	88.35	49.91	2571.11	20
5	95.54	54.98	2633.17	20
6	89.08	55.64	2674.92	20
7	78.49	47.61	2800.54	20
8	81.12	45.71	2656.69	20
9	88.78	50.47	2773.19	20
10	81.12	47.92	2683.00	20
Ortalama/ SS	84.05/ 0.064	49.77/ 0.035	2662.95/ 75.891	20

Tablo 4.2'de gösterilen 8 katmanlı KSA ve 20 tekrarlama sayısından oluşan deneysel çalışmaların sonucu gösterilmektedir. Bu deneysel çalışmada eğitim başarısı ortalama olarak %84 olarak hesaplanmaktadır. Test verileri ile elde edilen sınıflandırma başarısı ortalama olarak yaklaşık %50 olarak bulunmaktadır. Her bir deneysel çalışma yaklaşık olarak 2663 saniye sürmektedir. Sınıflandırma başarısı en yüksek deneysel çalışma %56 ile 6. testte elde edilmektedir.

İkinci olarak sıfırdan tasarlanan KSA 5 konvolüsyonel, 5 ReLu ve 4 havuzlama katmanı olmak üzere girdi, tam bağlantılı ve eşikleyici sınıflandırma katmanı ile birlikte toplam 17 katmandan oluşmaktadır. Şekil 4.3 ile 17 katmanlı KSA mimarisinin şeması verilmektedir. Sıfırdan tasarlanan bu KSA ile yapılan deneysel çalışmalar tablo 4.3 ve tablo 4.4'de sırası ile gösterilmektedir.



Şekil 4.3. 17 katmanlı KSA mimarisi

Tablo 4.3. 17 katmanlı KSA ve 10 tekrarlama sayısı ile yapılan deneysel çalışma sonuçları

KSA (17 Katmanlı)	Eğitim (%)	Test (%)	Süre (Sn.)	Tekrarlama Sayısı (Epoch)
1	96.49	65.20	1538.36	10
2	95.75	65.38	1563.88	10
3	95.49	60.58	1518.69	10
4	96.67	64.46	1500.01	10
5	94.08	64.18	1505.47	10
6	93.39	64.24	1745.55	10
7	95.05	63.67	1545.87	10
8	95.59	62.48	1549.79	10
9	91.83	57.38	1620.06	10
10	95.76	63.02	1606.57	10
Ortalama/ SS	95.01/ 0.015	63.06/ 0.024	1569.42/ 73.320	10

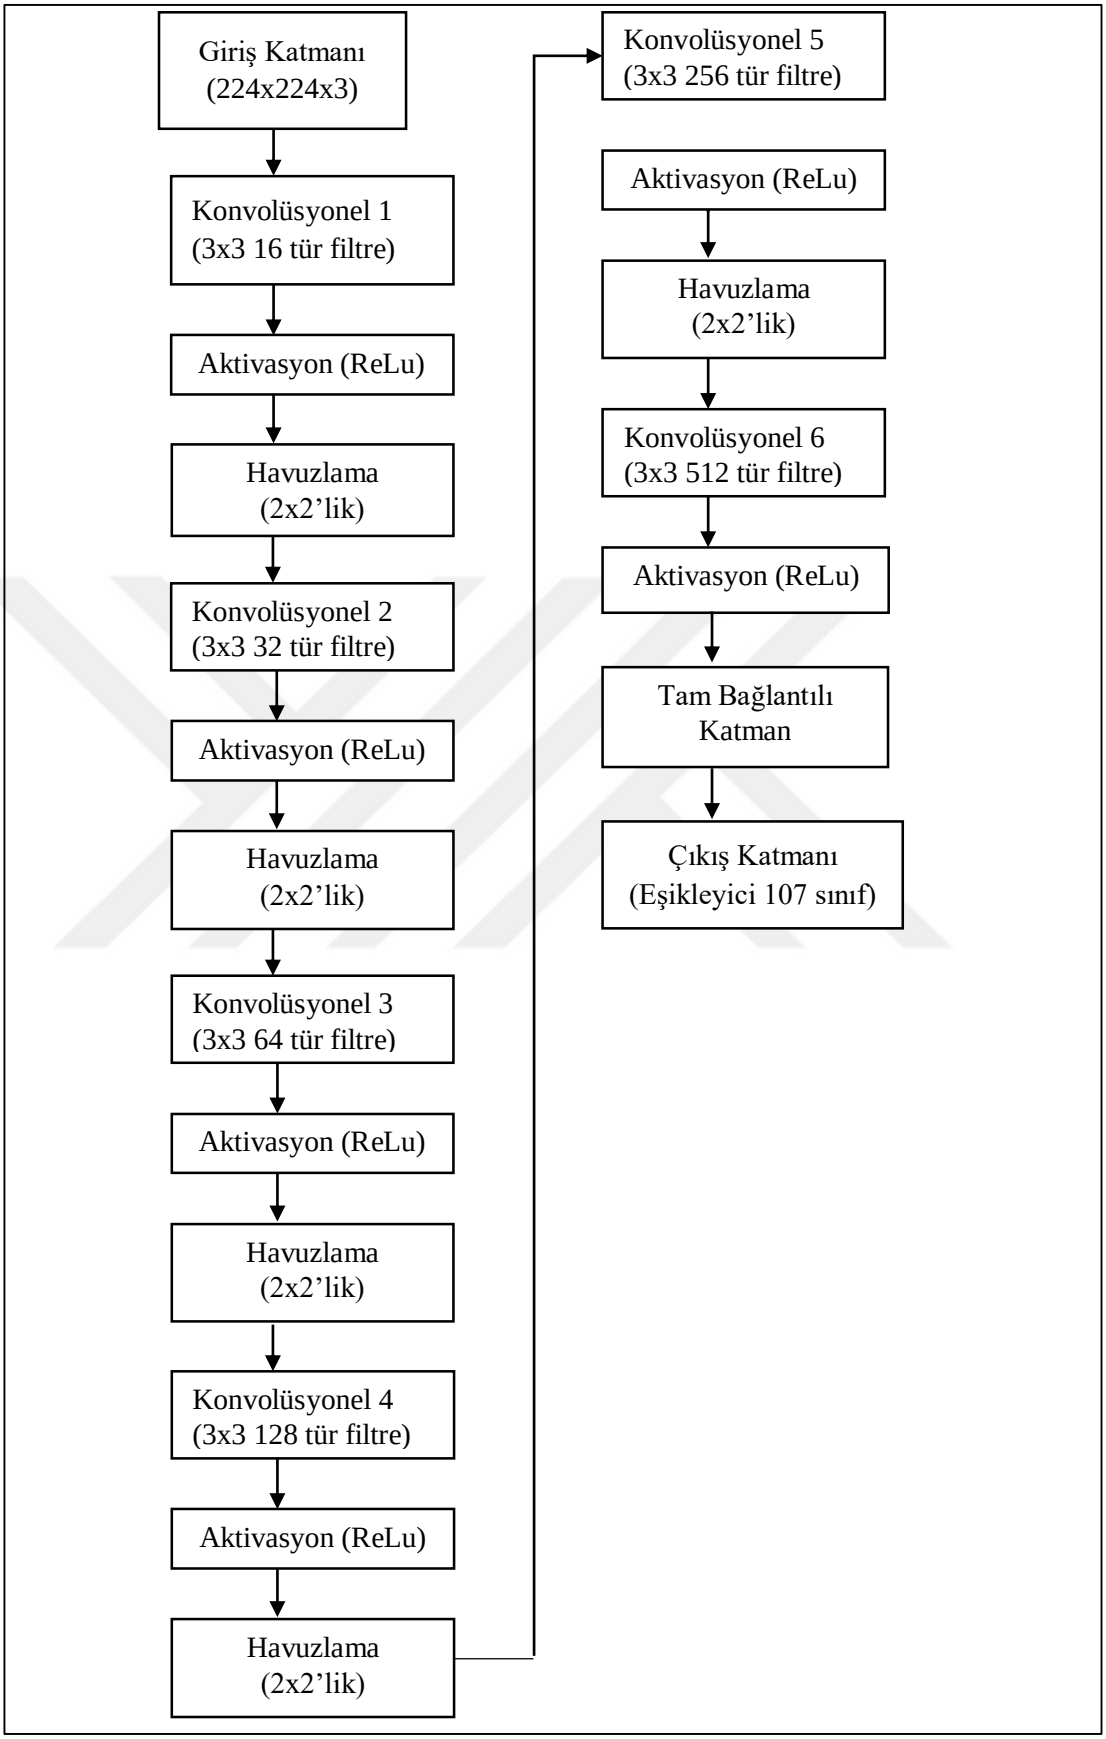
Tablo 4.3'de sıfırdan tasarlanan 17 katmanlı KSA ve 10 tekrarlama sayısı ile elde edilen deneysel çalışmaların sonuçları gösterilmektedir. Bu KSA ile eğitim veri kümesi %95'lik bir başarı ile eğitilmektedir. Test verileri ile elde edilen sınıflandırma başarısı ortalama olarak %63 'dür. Her bir deneysel çalışmanın çalışma süresi ortalama olarak 1569 saniye sürmektedir. Yapılan bu deneysel çalışmalardaki en yüksek sınıflandırma başarısı %65,3 ile 2. test çalışmasında elde edilmektedir.

Tablo 4.4. 17 katmanlı KSA ve 20 tekrarlama sayısı ile yapılan deneysel çalışma sonuçları

KSA (17 Katmanlı)	Eğitim (%)	Test (%)	Süre (Sn.)	Tekrarlama Sayısı (Epoch)
1	99.09	66.54	2892.25	20
2	99.03	68.65	2827.68	20
3	98.96	62.88	2789.07	20
4	99.07	67.29	2811.46	20
5	98.90	67.43	2810.77	20
6	98.98	69.59	2880.11	20
7	98.86	67.88	2931.86	20
8	98.88	62.29	2979.80	20
9	99.16	67.48	2968.92	20
10	99.13	66.42	2909.01	20
Ortalama/ SS	99.01/ 0.001	66.65/ 0.023	2880.09/ 68.349	20

Tablo 4.4'de sıfırdan tasarlanan 17 katmanlı KSA ve 20 tekrarlama sayısı ile elde edilen deneysel çalışmaların sonuçları gösterilmektedir. Bu KSA ile eğitim veri kümesi %99'luk bir başarı ile eğitilmektedir. Test verileri ile elde edilen sınıflandırma başarısı ortalama olarak %66,6'dır. Her bir deneysel çalışmanın çalışma süresi ortalama olarak 2880 saniye sürmektedir. Yapılan bu deneysel çalışmalardaki en yüksek sınıflandırma başarısı %69,6 ile 6. test çalışmasında elde edilmektedir.

Üçüncü olarak sıfırdan tasarlanan KSA 6 konvolüsyonel, 6 ReLu ve 5 havuzlama katmanı olmak üzere girdi, tam bağlantılı ve eşikleyici sınıflandırma katmanı ile birlikte toplam 20 katmandan oluşmaktadır. Şekil 4.4'de 20 katman olarak tasarlanan bu KSA'nın mimarisi gösterilmektedir. Sıfırdan tasarlanan bu KSA ile yapılan deneysel çalışmalar tablo 4.5 ve tablo 4.6'da sırası ile gösterilmektedir.



Şekil 4.4. 20 katmanlı KSA mimarisi

Tablo 4.5 20 katmanlı KSA ve 10 tekrarlama sayısı ile yapılan deneysel çalışma

KSA (20 Katmanlı)	Eğitim (%)	Test (%)	Süre (Sn.)	Tekrarlama Sayısı (Epoch)
1	92.76	63.09	1545.70	10
2	91.82	63.08	1534.62	10
3	91.48	59.04	1528.33	10
4	91.57	60.68	1512.14	10
5	91.24	63.41	1520.17	10
6	91.37	64.63	1601.47	10
7	93.74	60.99	1608.65	10
8	93.38	57.71	1543.99	10
9	90.82	59.07	1646.38	10
10	91.84	61.32	1612.01	10
Ortalama/SS	92.00/ 0.009	61.30/ 0.022	1565.35/ 47.084	10

Tablo 4.5'de sıfırdan tasarlanan 20 katmanlı KSA ve 10 tekrarlama sayısı ile elde edilen deneysel çalışmaların sonuçları gösterilmektedir. Bu KSA ile eğitim veri kümesi %92'lik bir başarı ile eğitilmektedir. Test verileri ile elde edilen sınıflandırma başarısı ortalama olarak %61,3'dür. Her bir deneysel çalışmanın çalışma süresi ortalama olarak 1565 saniye sürmektedir. Yapılan bu deneysel çalışmalardaki en yüksek sınıflandırma başarısı %64,6 ile 6. test çalışmasında elde edilmektedir.

Tablo 4.6. 20 Katmanlı KSA ve 20 tekrarlama sayısından oluşan deneysel çalıma sonuçları

KSA (20 Katmanlı)	Eğitim (%)	Test (%)	Süre (Sn.)	Tekrarlama Sayısı (Epoch)
1	98.58	66.73	2874.80	20
2	98.67	69.42	2838.00	20
3	98.44	66.15	2894.84	20
4	98.41	66.73	2821.29	20
5	98.22	68.39	3013.41	20
6	98.65	69.41	2902.64	20
7	98.96	67.88	3550.51	20
8	98.33	62.48	3065.40	20
9	99.17	67.10	3019.87	20
10	98.83	66.04	2944.46	20
Ortalama/SS	98.63/ 0.003	67.03/ 0.020	2992.52/ 212.088	20

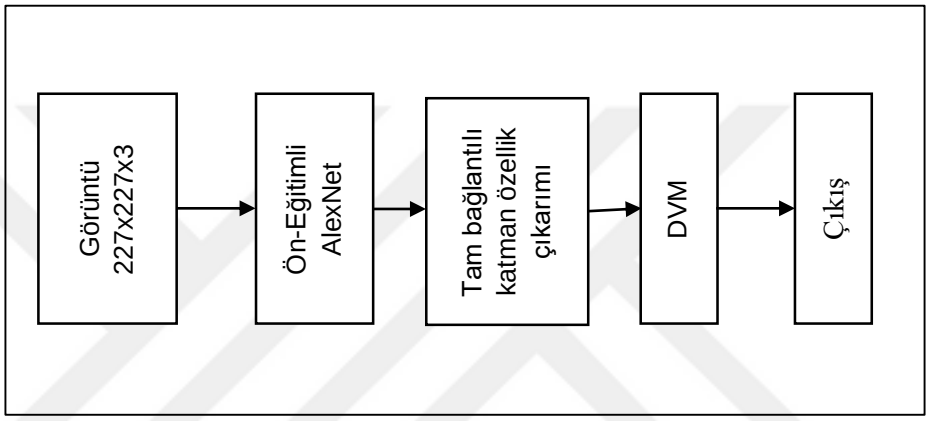
Tablo 4.6'da sıfırdan tasarlanan 20 katmanlı KSA ve 20 tekrarlama sayısı ile elde edilen deneysel çalışmaların sonuçları gösterilmektedir. Bu KSA ile eğitim veri kümesi %98,6'lık bir başarı ile eğitilmektedir. Test verileri ile elde edilen sınıflandırma doğruluk başarısı ortalama olarak %67.03'dür. Her bir deneysel çalışmanın çalışma süresi ortalama olarak 2992 saniye sürmektedir. Yapılan bu deneysel çalışmalardaki en yüksek sınıflandırma başarısı %69,4 ile 6. test çalışmasında elde edilmektedir.

4.2 AlexNet ile Transfer Öğrenme Çalışması

AlexNet derin öğrenme modeli ile transfer öğrenme yöntemleri (ince ayar ve özellik çıkarımı) kullanılarak yapılan deneysel çalışmaların sonuçları tablo 4.7 ve tablo 4.8'de gösterilmektedir. Yapılan deneysel çalışmalarda ayakkabı marka modellerini içeren ayakkabı veri kümesindeki görüntüler %90 eğitim ve %10 test verisi olarak parçalara ayrılmaktadır. Böylece 10 katlı çapraz doğrulama yöntemi ile sınıflama başarı sonuçları hesaplanarak elde edilmektedir. Her bir deneysel çalışma 20

tekrarlama sayısı (epoch) ile eğitilerek geriye yayılım algoritmasındaki ağırlık değerleri güncellenmektedir.

AlexNet derin öğrenme modeli ile özellik çıkarımı transfer öğrenme yöntemi kullanılarak DVM ile sınıflandırma yapılan deneysel çalışmanın akış diyagramı şekil 4.5'de gösterilmektedir.



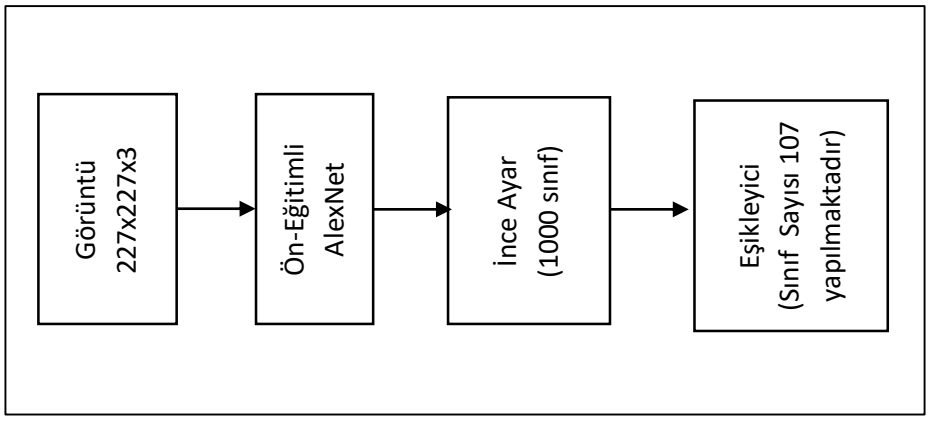
Şekil 4.5. AlexNet özellik çıkarımı ve DVM ile sınıflandırma yöntemi akış şeması

Tablo 4.7'de özellik çıkarımı yöntemi kullanılarak elde edilen sonuçlar gösterilmektedir. Bu amaçla yapılan deneysel çalışmada, ayakkabı marka modellerini içeren veri kümesindeki görüntülerin özellikleri AlexNet'in FC7 katmanından çıkarılmaktadır. Her bir görüntü için 4096 özellik elde edilmektedir. Daha sonra bu çıkarılan özellikler DVM makine öğrenme yöntemi ile sınıflandırılmaktadır. Veri kümesi 10 kat çapraz doğrulama yöntemi kullanılarak %90 eğitim ve %10 test verisi olarak parçalara ayrılmaktadır. Tekrarlama sayısı (epoch) 20 olarak kullanılmaktadır. Yapılan bu çalışmada 5. parçada %69.01 ile en yüksek başarı oranı elde edilirken 6. Parçada da %61.55 ile en düşük başarı oranı elde edilmektedir. Ortalama sınıflandırma başarısı oranı %65.46 değeri ile elde edilmektedir. Çalışma süresinin ortalama olarak 686.37 saniye sürdüğü tespit edilmektedir.

Tablo 4.7. AlexNet özellik çıkarımı yöntemi ve DVM ile sınıflandırma sonuçları

AlexNet-Özellik Çıkarımı-DVM	Eğitim (%)	Test (%)	Süre (Sn.)	Tekrarlama Sayısı (Epoch)
1	100.00	66.80	669.39	20
2	100.00	65.41	668.50	20
3	100.00	62.94	697.56	20
4	100.00	68.39	647.54	20
5	100.00	69.01	700.56	20
6	100.00	61.55	681.29	20
7	100.00	64.04	684.65	20
8	100.00	64.64	700.17	20
9	100.00	66.35	712.23	20
10	100.00	65.46	701.84	20
Ortalama/ SS	100.00	65.46/ 0.02	686.37/ 19.91	20

Şekil 4.6 ile Alexnet derin öğrenme modeline ince ayar transfer öğrenme uygulanması akış diyagramı halinde gösterilmektedir.



Şekil 4.6. AlexNet ince ayar yöntemi akış diyagramı

Tablo 4.8' de ince ayar yöntemi kullanılarak elde edilen başarı oranları gösterilmektedir. Bu amaçla yapılan deneysel çalışmada AlexNet modelinin FC8

katmanında ki 1000 olan sınıf sayısı kullanılan veri kümesindeki 107 olan sınıf sayısı ile değiştirilerek eğitilmektedir. Deneysel çalışmada 10 çapraz doğrulama kullanılmaktadır ve veriler %90 eğitim ve %10 test verisi olarak ayrılmaktadır. Tekrarlama sayısı 20 olarak belirlenmektedir. Elde edilen sonuçlar doğrultusunda en yüksek başarı oranı 1. parçada %74.58, en düşük sınıflandırma başarısı ise %71.70 ile 5. parçada elde edilmektedir. Ortalama sınıflandırma başarısı %72.87 olarak hesaplanmaktadır. Çalışma süresinin ortalama olarak 2607.24 saniye sürmekte olduğu tespit edilmektedir. Test parçaları arasındaki standart sapma (ss) oranının 0.01 olması başarının tutarlı olduğunu göstermektedir.

Tablo 4.8. AlexNet ile ince ayar transfer öğrenme yöntemi sonuçları

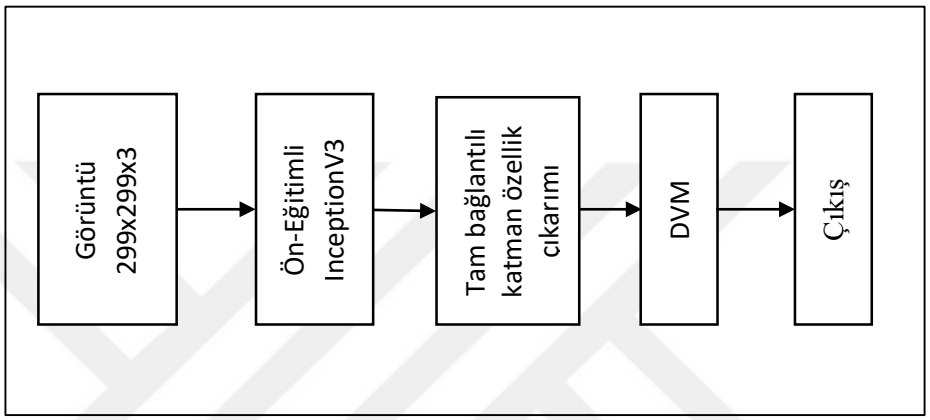
AlexNet-İnce Ayar	Eğitim (%)	Test (%)	Süre (Sn.)	Tekrarlama Sayısı (Epoch)
1	96.96	74.58	2577.51	20
2	97.14	72.10	2596.32	20
3	96.89	73.11	2661.70	20
4	97.33	74.24	2644.79	20
5	97.25	71.70	2630.27	20
6	97.27	71.76	2608.46	20
7	97.38	72.20	2569.81	20
8	97.00	72.06	2610.24	20
9	97.04	73.38	2607.92	20
10	97.25	73.56	2565.34	20
Ortalama/SS	97.15/ 0.002	72.87/ 0.01	2607.24/ 31.76	

4.3 InceptionV3 ile Transfer Öğrenme Çalışması

InceptionV3 derin öğrenme modeli ile transfer öğrenme yapılarak elde edilen deneysel çalışmaların sonuçları sırası ile tablo 4.9 ve tablo 4.10 de gösterilmektedir. Bu deneysel çalışmalarda ayakkabı veri kümesindeki görüntüler 10 çapraz doğrulama kullanılarak %90 eğitim ve %10 test verisi olarak ayrılmaktadır. Hesaplamalar 20

tekrarlama sayısı (epoch) ile yapılmaktadır.

InceptionV3 derin öğrenme modeli kullanılarak özellik çıkarımı transfer öğrenme yöntemi ve DVM ile sınıflandırma yapılarak yapılan deneysel çalışmanın akış diyagramı şekil 4.7'de gösterilmektedir.



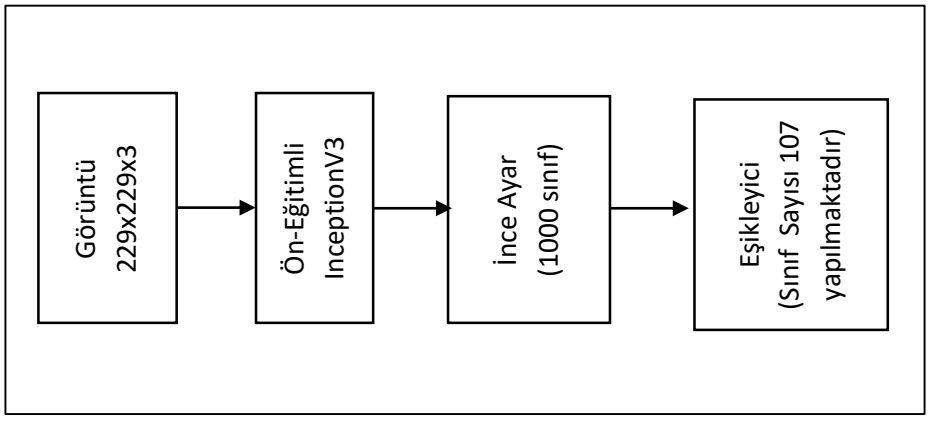
Şekil 4.7. InceptionV3 özellik çıkarımı ve DVM akış diyagramı

Tablo 4.9'da gösterilen deneysel çalışma ile InceptionV3 derin öğrenme modeli ile transfer öğrenme yapılarak özellik çıkarımı yöntemi ile ayakkabı marka modellerini içeren veri kümesindeki görüntülerin özellikleri çıkarılmaktadır. Çıkarılan özellikler derin öğrenme modelinin tam bağlantılı katmanından elde edilmektedir. Elde edilen bu özellikler DVM yöntemi ile kullanılarak sınıflandırma doğruluk başarı oranı ve hesaplama boyunca geçen süre hesaplanmaktadır. Her bir deneysel çalışma sonucunda eğitim veri kümesi %100 başarı ile eğitilmektedir, yapılan test hesaplamaları sonucunda ortalama olarak %64.04 sınıflandırma doğruluk başarısı elde edilmektedir. Deneylerin her biri yaklaşık olarak 3.79'luk bir standart sapma ile ortalama 206.96 saniye sürmektedir. Yapılan bu deneysel çalışma içerisindeki sınıflandırma doğruluk başarı oranı en yüksek olan test hesaplaması %68.83 ile 3. testte elde edilmektedir.

Tablo 4.9. InceptionV3 ile Özellik çıkarımı ve DVM sınıflandırma sonuçları

InceptionV3-Özellik Çıkarımı-DVM	Eğitim (%)	Test (%)	Süre (Sn.)	Tekrarlama Sayısı (Epoch)
1	100.0	62.96	215.80	20
2	100.0	63.10	205.37	20
3	100.0	68.83	206.82	20
4	100.0	63.12	204.01	20
5	100.0	62.91	202.80	20
6	100.0	64.84	205.73	20
7	100.0	59.54	211.03	20
8	100.0	63.60	205.38	20
9	100.0	65.23	205.58	20
10	100.0	66.22	207.03	20
Ortalama/SS	100.0	64.04/ 0.026	206.96/ 3.79	20

İnce ayar transfer öğrenme yöntemi kullanılarak yapılan deneysel çalışmanın akış diyagramı şekil 4.8'de gösterilmektedir.



Şekil 4.8. InceptionV3 ve ince ayar yöntemi akış diyagramı

Tablo 4.10'da yapılan deneysel çalışma ile InceptionV3 derin öğrenme modelinden ince ayar transfer öğrenme yöntemi kullanılarak sınıflandırma başarısı hesaplanmaktadır. İnce ayar yöntemi ile InceptionV3 derin öğrenme modelinin eşikleyici katmanındaki sınıf sayısı ayakkabı veri kümesinin 107 olan sınıf sayısı ile değiştirilerek eğitim ve test işlemleri yapılmaktadır. Yapılan deneysel çalışma sonucunda eğitim başarısı yaklaşık olarak ortalama %43 hesaplanmaktadır. Test verilerinin sınıflandırma doğruluk oranı yaklaşık olarak 0.019'luk standart sapma ile %38.01 bulunmaktadır. Deneysel testlerin çalışma süreleri ortalama olarak 15102.9 saniye sürmektedir. Bu deneysel çalışma içerisindeki en başarılı sınıflandırma doğruluk oranı %39.96 ile 10. testte elde edilmektedir.

Tablo 4.10. InceptionV3 derin öğrenme modeli ile ince ayar yöntemi sonuçları

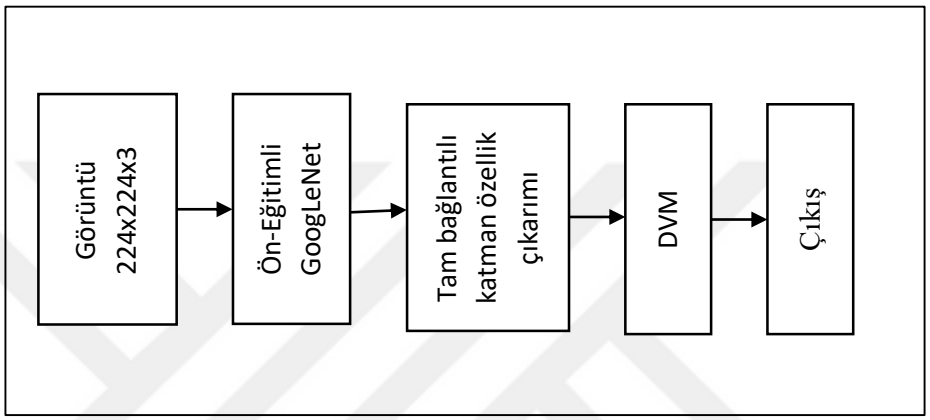
InceptionV3-İnce Ayar	Eğitim (%)	Test (%)	Süre (Sn.)	Tekrarlama Sayısı (Epoch)
1	43.40	38.14	15176.77	20
2	42.58	39.31	15055.78	20
3	43.17	39.27	15069.32	20
4	42.62	39.51	15083.60	20
5	43.01	36.74	15042.05	20
6	42.66	36.11	15041.26	20
7	43.25	39.85	15200.69	20
8	43.85	36.70	15190.23	20
9	43.04	34.48	15108.69	20
10	43.26	39.96	15060.62	20
Ortalama/SS	43.08/ 0.004	38.01/ 0.019	15102.9/ 62.97	20

4.4 GoogLeNet ile Transfer Öğrenme Çalışması

GoogLeNet derin öğrenme modeli ile transfer öğrenme yapılarak elde edilen deneysel çalışmaların sonuçları sırası ile tablo 4.11 ve tablo 4.12'de gösterilmektedir. Bu deneysel çalışmalarda ayakkabı veri kümesindeki görüntüler 10 çapraz doğrulama

kullanılarak %90 eğitim ve %10 test verisi olarak ayrılmaktadır. Hesaplamalar 20 tekrarlama sayısı (epoch) ile yapılmaktadır.

Şekil 4.9'da GoogLeNet kullanılarak özellik çıkarımı ve DVM ile yapılan deneysel çalışmanın akış diyagramı gösterilmektedir.



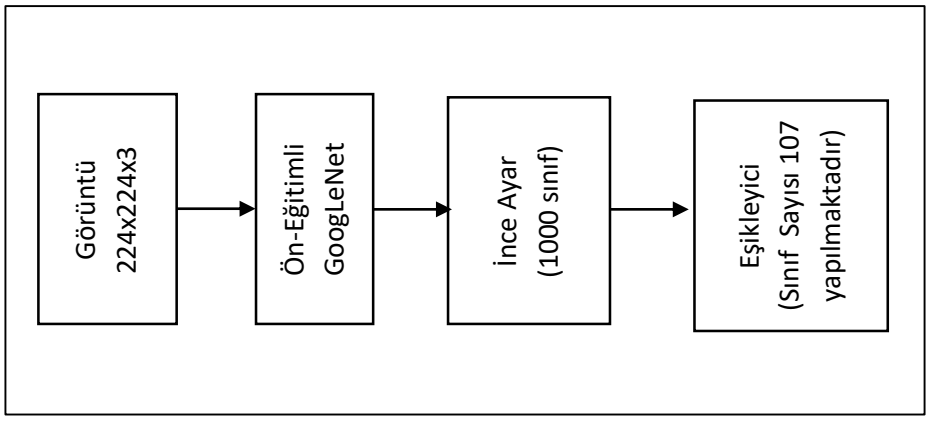
Şekil 4.9. GoogLeNet kullanılarak özellik çıkarımı ve SVM ile sınıflandırma akış diyagramı

Tablo 4.11'de gösterilen deneysel çalışma ile GoogLeNet derin öğrenme modeli ile transfer öğrenme yapılarak özellik çıkarımı yöntemi ile ayakkabı marka modellerini içeren veri kümesindeki görüntülerin özellikleri çıkarılmaktadır. Çıkarılan özellikler derin öğrenme modelinin tam bağlantılı katmanından elde edilmektedir. Elde edilen bu özellikler ile DVM yöntemi kullanılarak sınıflandırma doğruluk başarı oranı ve hesaplama boyunca geçen süre hesaplanmaktadır. Her bir deneysel çalışma sonucunda eğitim veri kümesi %100 başarı ile eğitilmektedir, yapılan test hesaplamaları sonucunda ortalama olarak %61.81 sınıflandırma doğruluk başarısı elde edilmektedir. Deneylerin her biri yaklaşık olarak 1.431'lik bir standart sapma ile ortalama olarak 121.91 saniye sürmektedir. Yapılan bu deneysel çalışma içerisindeki sınıflandırma doğruluk başarı oranı en yüksek olan test hesaplaması %64.15 ile 6. testte elde edilmektedir.

Tablo 4.11. GoogLeNet ile özellik çıkarımı yöntemi kullanılarak DVM ile sınıflandırmada elde edilen sonuçlar

GoogLeNet-Özellik Çıkarımı-DVM	Eğitim (%)	Test (%)	Süre (Sn.)	Tekrarlama Sayısı (Epoch)
1	100.0	63.62	123.36	20
2	100.0	63.97	122.64	20
3	100.0	57.63	122.62	20
4	100.0	60.19	120.33	20
5	100.0	62.90	123.20	20
6	100.0	64.15	123.67	20
7	100.0	62.67	121.87	20
8	100.0	61.90	119.84	20
9	100.0	60.27	120.00	20
10	100.0	60.79	121.58	20
Ortalama/SS	100.0	61.81/ 0.021	121.91/ 1.431	20

Şekil 4.10 ile GoogLeNet derin öğrenme modeli kullanılarak ince ayar transfer öğrenme yöntemi ile yapılan deneysel çalışmanın akış diyagramı gösterilmektedir.



Şekil 4.10. GoogLeNet ile ince ayar transfer öğrenme yöntemi akış diyagramı

GoogLeNet derin öğrenme modeline ince ayar transfer öğrenme yöntemi uygulanarak sınıflandırma doğruluk başarısı hesaplanmaktadır ve sonuçlar tablo

4.12'de gösterilmektedir. İnce ayar transfer öğrenme yöntemi kullanılarak GoogLeNet derin öğrenme modelinin eşikleyici katmanındaki sınıf sayısı ayakkabı veri kümesinin 107 olan sınıf sayısı ile değiştirilerek eğitim ve test hesaplamaları yapılmaktadır. Elde edilen sonuçlara göre eğitim ortalama olarak 0.005'lik standart sapma ile %78.94 ile tamamlanmaktadır. Yapılan testler sonucu sınıflandırma doğruluk başarı oranı 0.031'lik standart sapma ile %63.49 olarak elde edilmektedir. Deneysel çalışmaların çalışma süreleri ortalama olarak 57.455'lik standart sapma ile 3170.87 saniye sürmektedir. GoogLeNet ile ince ayar yöntemi kullanılarak yapılan deneysel çalışma içerisindeki en başarılı sınıflandırma doğruluk oranı %68.76 ile 8. testte elde edilmektedir.

Tablo 4.12. GoogLeNet ile ince ayar yöntemi deneysel çalışmasından elde edilen sonuçlar

GoogLeNet-İnce Ayar	Eğitim (%)	Test (%)	Süre (Sn.)	Tekrarlama Sayısı (Epoch)
1	78.83	61.32	3022.49	20
2	79.64	61.25	3210.86	20
3	78.48	62.57	3197.76	20
4	79.65	67.43	3199.54	20
5	78.53	64.02	3175.62	20
6	78.94	60.65	3190.84	20
7	78.22	58.94	3153.40	20
8	79.17	68.76	3153.42	20
9	79.04	65.07	3230.06	20
10	78.89	64.89	3174.69	20
Ortalama/SS	78.94/ 0.005	63.49/ 0.031	3170.87/57.455	20

5. SONUÇLAR VE ÖNERİLER

Yapılan bu tez çalışmasındaki tüm deneylerin ortalama eğitim, test, çalışma süreleri sonuçları ve standart sapma oranları tablo 5.1'de gösterilmektedir. Tablo 5.1. deki eğitim başarı değerleri deneysel çalışmalardaki eğitim için kullanılan veri kümelerinin eğitildikten sonra, eğitim verilerinin tekrar sınıflandırılması sonucunda elde edilen sınıflandırma doğruluk oranlarını göstermektedir. Test verilerinin sınıflandırılması ile elde edilen başarı oranları eğitim boyunca hiç kullanılmayan verilerin sınıflandırılması ile bulunmaktadır. Yapılan deneysel çalışmalar sonucunda derin öğrenme modellerine uygulanacak transfer öğrenme yöntemleri sınıflandırma doğruluk oranı ve zaman açısından daha başarılı olduğu gözlemlenmiştir. Bu deneysel çalışmalar gösteriyor ki donanımsal ihtiyaçların maliyetini azaltmak ve zamandan tasarruf etmek edebilmek için derin öğrenme modellerine transfer öğrenme yapmak sıfırdan KSA tasarlamaktan daha avantajlı olmaktadır.

Elde edilen sonuçlara göre bu deneysel çalışmalar içerisinde çalışma süresi bakımından en kısa sürede çalışan deney 121.91 saniye ile GoogLeNet derin öğrenme modeli kullanılarak ayakkabı veri kümesinin özellik çıkarımı yapıldıktan sonra DVM yöntemi ile sınıflandırma doğruluk başarı oranı tespit edilen çalışma sürmektedir.

Yapılan deneysel çalışmalar içerisinde test verileri ile elde edilen sınıflandırma doğruluk başarı oranı en yüksek olan deney %72.87'dir. Bu başarılı sonuç AlexNet derin öğrenme modelinin 1000 olan sınıf sayısının ayakkabı veri kümesinin 107 olan sınıf sayısının ince ayar yöntemi kullanılarak değiştirilmesi ile elde edilmektedir.

Yapılan deneysel çalışmalar sonucunda AlexNet derin öğrenme modelinin bu tez çalışmasında kullanılan diğer derin öğrenme modellerine göre ayakkabı veri kümesini sınıflandırmak için kullanılacak en iyi derin öğrenme modeli olduğu gözlemlenmektedir.

Tablo 5.1. Tüm deneysel çalışmaların sonuçları

Deneyler Ortalama /SS	Eğitim (%)	Test (%)	Süre (Sn.)	Tekrarlama Sayısı (Epoch)
KSA (8 Katman)	71.47 /0.086	45.55 /0.042	1433.80 /54.102	10
KSA (17 Katman)	95.01 /0.015	63.06 /0.024	1569.42 /73.220	10
KSA (20 Katman)	92.00 /0.009	61.30 /0.022	1565.35 /47.084	10
KSA (8 Katman)	84.05 /0.064	49.77 /0.035	2662.95 /75.891	20
KSA (17 Katman)	99.01 /0.001	66.65 /0.023	2880.09 /68.349	20
KSA (20 Katman)	98.63 /0.003	67.03 /0.020	2992.52 /212.088	20
AlexNet-Özellik Çıkarımı-DVM	100.00	65.46 /0.02	686.37 /19.91	20
AlexNet-İnce Ayar	97.15 /0.002	72.87 /0.01	2607.24 /31.76	20
InceptionV3-Özellik Çıkarımı-DVM	100.00	64.04 /0.026	206.96 /3.79	20
InceptionV3-İnce Ayar	43.08 /0.004	38.01 /0.019	15102.9 /62.97	20
GoogLeNet-Özellik Çıkarımı-DVM	100.00	61.81 /0.021	121.91 /1.431	20
GoogLeNet-İnce Ayar	78.94 /0.005	63.49 /0.031	3170.87 /57.455	20

Derin öğrenme modellerine uygulanan transfer öğrenme yöntemleri kendi aralarında kıyaslandığı zaman InceptionV3 derin öğrenme modeli ile yapılan transfer öğrenme çalışmaları sonucunda özellik çıkarımı yönteminin ince ayar yöntemine göre sınıflandırma doğruluk oranının daha yüksek olduğu tespit edilmektedir. Bu iki yöntemin InceptionV3 modelinde sınıflandırma hesaplama süreleri de kıyaslandığı zaman yine özellik çıkarımı yöntemi ve DVM kullanılarak yapılan deneysel

çalışmanın daha kısa sürede sınıflandırma işleminin tamamlandığı gözlemlenmektedir.

AlexNet derin öğrenme modeline uygulanan transfer öğrenme yöntemleri kıyaslandığı zaman ince ayar transfer öğrenme yönteminin özellik çıkarımı transfer öğrenme yöntemi ve DVM ile sınıflandırma yapılan deneysel çalışmaya göre sınıflandırma doğruluk oranının daha başarılı olduğu görülmektedir. Çalışma süresi bakımından kıyaslandığında özellik çıkarımı ve DVM yönteminin daha kısa süre sınıflandırma yaptığı gözlemlenmektedir.

GoogLeNet derin öğrenme modeline uygulanan transfer öğrenme yöntemlerinden ince ayar yönteminin diğer transfer öğrenme yöntemi ile yapılan deneysel çalışmaya göre daha başarılı sınıflandırma doğruluk oranı elde ettiği görülmektedir. Bu iki yöntemin sınıflandırma hesaplama süreleri kıyaslandığında özellik çıkarımı ve DVM kullanılarak yapılan deneysel çalışmanın daha kısa sürede tamamlandığı gözlemlenmektedir.

Derin öğrenme modellerine uygulanan transfer öğrenme yöntemlerinden özellik çıkarımı ve DVM ile yapılan deneysel çalışmalar kıyaslandığı zaman AlexNet kullanılarak yapılan deneysel çalışmanın diğer derin öğrenme modellerine göre sınıflandırma doğruluk başarı oranının daha yüksek olduğu görülmektedir. Hesaplama süreleri bakımından GoogLeNet derin öğrenme modelinin diğer modellere göre daha kısa sürede işlem yaptığı gözlemlenmektedir.

İnce ayar transfer öğrenme yönteminin derin öğrenme modellerine uygulanarak yapılan deneysel çalışmalarda sınıflandırma doğruluk oranları kıyaslandığı zaman yine AlexNet derin öğrenme modelinin diğer modellere göre daha başarılı sonuç verdiği görülmektedir. Çalışma süreleri bakımından kıyaslandığında ise AlexNet derin öğrenme modelinin diğer modellere oranla daha kısa sürede işlem yaptığı görülmektedir.

Sıfırdan tasarlanan KSA mimarileri kendi aralarında kıyaslandığı zaman 10 tekrarlama sayısı kullanılarak yapılan deneysel çalışmalarda sınıflandırma doğruluk oranı başarılı olan deney 17 katmanlı KSA mimarisi olmaktadır. Çalışma süresi bakımından 10 tekrarlama sayısı ile yapılan deneysel çalımalar içerisinde hesaplamayı daha kısa süre içerisinde yapan 8 katmanlı KSA mimarisi olmaktadır. Eğitim başarı oranlarına bakıldığı zaman ise yine 17 katmanlı KSA mimarisi daha başarılıdır.

Sıfırdan tasarlanan KSA mimarileri ve 20 tekrarlama sayısı kullanılarak yapılan deneysel çalışmalar kıyaslandığı zaman 20 katmanlı KSA mimarisinin diğer tasarlanan KSA mimarilerine oranla sınıflandırma doğruluk başarı oranı açısından daha iyi sonuç verdiği gözlemlenmektedir. Çalışma süresi bakımından daha kısa sürede hesaplamayı 8 katmanlı KSA yapmaktadır. Eğitim başarı oranı diğerlerine göre yüksek olan 17 katmanlı KSA mimarisi olmaktadır.

Sıfırdan tasarlanan KSA mimarilerinde 10 ve 20 tekrarlama sayısı kullanılarak yapılan deneysel çalışmalar içerisinde en yüksek sınıflandırma doğruluk başarı oranı 20 katmanlı KSA mimarisinin 20 tekrarlama sayısı ile kullanılması sonucu elde edilmektedir. Çalışma süreleri bakımından ise 8 katmanlı ve 10 tekrarlama sayılı KSA daha kısa sürede çalışmaktadır fakat eğitim başarı oranı ve çalışma süresi diğerlerine göre daha başarısız olmaktadır. Bu deneysel çalışmaların sınıflandırma başarı sonuçları yüzdelik olarak kıyaslandığı zaman 17 katmanlı ve 20 katmanlı KSA mimarilerinin aralarında %0,38'lik fark olduğu görülmektedir. Yine çalışma süresi ve eğitim başarı oranları arasında da küçük farklılıklar bulunmaktadır. Bu nedenlerden dolayı sıfırdan tasarlanacak olan KSA mimarisinde çok fazla konvolüsyonel katman kullanmanın sınıflandırma başarı oranına büyük etkileri olmadığı bu deneysel çalışmalar ile gözlemlenmektedir.

Derin öğrenme modellerine transfer öğrenme uygulanarak yapılan deneysel çalışmalar içerisinde en başarılı sınıflandırma doğruluk oranına sahip olan AlexNet derin öğrenme modeli ve ince ayar transfer öğrenme yöntemi ile sıfırdan tasarlanan en

başarılı sınıflandırma doğruluk oranına sahip olan 20 katmanlı KSA mimarisi kıyaslandığı zaman transfer öğrenme ile yapılan deneysel çalışmanın daha başarılı olduğu görülmektedir. Çalışma süreleri bakımından da yine AlexNet derin öğrenme modelinin daha hızlı hesaplama yaptığı tespit edilmektedir.

Literatürde ayakkabı veri kümesi ile farklı makine öğrenme yöntemleri ve derin öğrenme yöntemleri kullanılarak yapılan diğer çalışmalarda elde edilen sonuçlar tablo 5.2'de gösterilmektedir.

Tablo 5.2. Literatürde ayakkabı veri kümesi sınıflandırmak için önerilen yöntemlerin sonuçları

Ayakkabı Veri Kümesi İle Yapılan Literatürdeki Çalışmalar	Sınıflandırma Doğruluk Başarı Oranları
Nesne hiyerarşisinden orta düzeyli özellikleri öğrenme (Albaradei ve ark., 2014)	%64.7
İki-akış modeli (two-flow model) (Ilikovich ve ark., 2016)	%70,5
AlexNet+ince ayar yöntemi	**%72.87**
AVGnet (Korzh ve ark., 2018)	%92.00

Albaradei ve ark. (2014) tarafından önerilen çalışmada düşük seviyeli özellikler (low level features) renk histogramı gibi yöntemler kullanılarak çıkarılmakta ve non-lineer sınıflandırıcılar ile sınıflandırılmaktadır. Ayakkabı veri kümesi 10 üst sınıfa bölünmüştür. Örneğin çizme üst sınıfına bağlı olarak 13 sınıf (ariat western çizme, justin batı botları gibi) bulunmaktadır. Elde edilen başarı oranı %64.7 ile bu tez çalışmasında önceden eğitilmiş AlexNet modeli ve ince ayar kullanılarak yapılan çalışmaya kıyasla daha az başarılı olduğu görülmektedir.

Iliukovich-Strakovskaia ve ark. (2016) tarafından yapılan çalışmada %70,5 lik başarı elde edilmektedir. İki farklı yöntem (boyut azaltma temelli bir yaklaşım kullanılarak özellik çıkarımı ve önceden eğitilmiş derin öğrenme modelinden özellik çıkarımı) kullanılarak ayakkabı görüntülerinin özellikleri çıkarılarak birleştirilip

rastgele orman sınıflandırıcısı ile sınıflandırılmaktadır. Önerilen bu yöntem ile yapılan çalışma, tez çalışmasındaki en başarılı deneysel çalışma olan AlexNet ve ince ayar yönteminden daha az başarı göstermektedir.

Korzh ve ark. (2018) tarafından önerdikleri yöntemler ile yaptıkları deneysel çalışmalar içerisindeki en başarılı sonucu %92.00 ile AVGnet yöntemi olmaktadır. Bu yöntem üç tane önceden eğitilmiş derin öğrenme modeli kullanılarak (AlexNet, VGG19 ve GoogLeNet) yeni bir model oluşturulmaktadır. Bu model transfer öğrenme yöntemleri (ince ayar ve özellik çıkarımı) ile eğitilerek görüntülerin özellikleri çıkarılmaktadır. Daha sonra DVM yöntemi ile sınıflandırılmaktadır. Derin öğrenme modellerinin hibrit yapıda kullanılarak transfer öğrenme yöntemleri kullanılması bu tez çalışmasında yaptığımız tek derin öğrenme modeli ve tek transfer öğreneme yöntemine göre daha başarılı sonuç vermektedir.

Literatürde önerilen yöntemlerle yapılan ve bu tez çalışmasında yapılan deneysel çalışmalar sonucunda önceden eğitilmiş derin öğrenme modellerinden transfer öğrenme yöntemleri kullanılarak ayakkabı görüntülerinin sınıflandırılmasının daha başarılı olduğu gözlemlenmektedir.

KAYNAKLAR

AKTAN, E., 2018. Büyük Veri: Uygulama Alanları, Analitiği Ve Güvenlik Boyutu. Bilgi Yönetimi, 1.1: 1-22.

ALBARADEI, S., WANG, Y., CAO, L. and LI, L. J., 2014. Learning Mid-Level Features From Object Hierarchy For Image Classification. In IEEE Winter Conference on Applications of Computer Vision, pp. 235-240.

ASEFİSARAY, B., HAZNEDAROĞLU, A., ERDEN, M. ve ARSLAN, L. M., 2018. Transfer Learning For Automatic Speech Recognition Systems. In 2018 26th Signal Processing and Communications Applications Conference (SIU), pp. 1-4.

AYHAN, S. ve ERDOĞMUŞ, Ş., 2014. Destek Vektör Makineleriyle Sınıflandırma Problemlerinin Çözümü İçin Çekirdek Fonksiyonu Seçimi. Eskişehir Osmangazi Üniversitesi İİBF Dergisi, 9(1), 175- 198.

CIRESAN, D. C., MEIER, U., MASCI, J., MARIA GAMBARDELLA, L. and SCHMIDHUBER, J., 2011. Flexible, High Performance Convolutional Neural Networks For Image Classification. In IJCAI Proceedings-International Joint Conference on Artificial Intelligence ,Vol. 22, No. 1, p. 1237.

CORTES, C. VE VAPNIK, V., 1995. Support Vector Networks. Machine Learning, 20,1-25.

DEMİREZ ÖRS, D. Z., 2018. Farklı Dalga Boylu Görüntülerle Buğday Sınıflandırılması. Eskişehir Osmangazi Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 79s.

DENG, J., DONG, W., SOCHER, R., LI, L. J., LI, K., ve FEI-FEI, L., 2009. Imagenet: A Large-Scale Hierarchical Image Database. In 2009 IEEE Conference On Computer Vision And Pattern Recognition, pp:248-255.

DOĞAN, F. ve TÜRKOĞLU, İ., 2018. Derin Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması. Sakarya University Journal Of Computer And Information Sciences Vol. 1, Id.

DOĞAN, F. ve TÜRKOĞLU, İ., 2019. Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. DÜMF Mühendislik Dergisi 10:2 (2019) : 409-445.

GÜRKAYNAK, C. D., 2018. Evrişimli Sinir Ağlarında Eğitim Transferi İle Gemi Sınıflandırma, Doğrulama Ve Tanıma. Bahçeşehir Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 47s.

GÜNDÜZ, G. ve CEDİMOĞLU, İ.H., 2019. Derin Öğrenme Algoritmalarını Kullanarak Görüntüden Cinsiyet Tahmini. Sakarya University Journal of Computer and Information Sciences. 2.1: 9-17.

HINTON, G., DENG, L., YU, D., DAHL, G. E., MOHAMED, A. R., JAITLY, N., and KINGSBURY, B., 2012. Deep Neural Networks For Acoustic Modeling İn Speech Recognition: The Shared Views Of Four Research Groups. IEEE Signal Processing Magazine, 29(6), 82-97.

HINTON, G. E., SRIVASTAVA, N., KRIZHEVSKY, A., SUTSKEVER, I. and SALAKHUTDINOV, R. R., 2012. Improving Neural Networks By Preventing Co-Adaptation Of Feature Detectors. arXiv preprint arXiv:1207.0580.

ILIUKOVICH-STRAKOVSKAIA, A., DRAL, A. AND DRAL, E., 2016. Using Pre-Trained Models For Fine-Grained İmage Classification İn Fashion Field. In Proceedings of the First International Workshop on Fashion and KDD, pp: 31-40.
İNİK, Ö. VE ÜLKER, E., 2017. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. Gaziosmanpaşa Bilimsel Araştırma Dergisi (GBAD), cilt 6, sayı 3, pp. 85-104.
KARPATHY, A. ve FEI-FEI, L., 2015. Deep Visual-Semantic Alignments For Generating Image Descriptions. In Proceedings Of The IEEE Conference On Computer Vision And Pattern Recognition, pp. 3128-3137.
KIN, Z.B., 2019. Türk İşaret Dili Alfabesinin Derin Öğrenme Yöntemi İle Sınıflandırılması. Başkent Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 92s.
KRIZHEVSKY, A., SUTSKEVER, I. and HINTON, G. E., 2012. Imagenet Classification With Deep Convolutional Neural Networks. In Advances İn Neural İnformation Processing Systems, pp. 1097-1105.
KURT, M. S., 2018. Derin Öğrenme Modelleri İle Web Sayfası Sınıflandırma. İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 49s.
KIZRAK, M. A. ve BOLAT, B., 2018. Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma. Bilişim Teknolojileri Dergisi, 11(3), 263-286.
KORZH, O., JOARISTI, M. and SERRA, E., 2018. Convolutional Neural Network Ensemble Fine-Tuning for Extended Transfer Learning. In: International Conference on Big Data. Springer, Cham, p. 110-123.
LIN, M., CHEN, Q. and YAN, S., 2013. Network in Network. arXiv preprint arXiv:1312.4400.
MUTLU, H. E., 2018. Hiperspektral Görüntü Ve Lidar Verisinin Derin Öğrenme İle Sınıflandırılması. Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 92s.
NAİR, V. ve HİNTON, G. E., 2010. Rectified Linear Units İmprove Restricted Boltzmann Machines. In Proceedings of the 27th international conference on machine learning (ICML-10) (pp. 807-814).
PANG, Y., SUN, M., JIANG, X. and LI, X., 2017. Convolution in Convolution For Network in Network. IEEE Transactions On Neural Networks And Learning Systems, 29(5), 1587-1597.
SALUR, M. U. ve AYDIN, İ., 2018. Sentiment Classification Based On Deep Learning. In: 2018 26th Signal Processing and Communications Applications Conference (SIU), IEEE, p. 1-4.
SEN, Ö. ve KELES, H. Y., 2019. Scene Recognition with Deep Learning Methods Using Aerial Images. In: 2019 27th Signal Processing and Communications Applications Conference (SIU). IEEE, p. 1-4.
SRIVASTAVA, N., HINTON, G., KRIZHEVSKY, A., SUTSKEVER, I. and SALAKHUTDINOV, R., 2014. Dropout: A Simple Way To Prevent Neural Networks From Overfitting. The Journal of Machine Learning Research, 15(1), 1929-1958.
SZEGEDY, C., WEI, L., YANGQING, J., PIERRE, S., SCOTT, R., DRAGOMIR, A., DUMITRU, E., VINCENT, V. and ANDREW, R., 2015. Going Deeper With Convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 1-9.

SZEGEDY, C., VANHOUCKE, V., IOFFE, S., SHLENS,J., and WOJNA, Z., 2016. Rethinking The İnception Architecture For Computer Vision. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 2818-2826.
ŞEKER, A., DİRİ, B. ve BALIK, H. H, 2017. Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. Gazi Mühendislik Bilimleri Dergisi, 3(3): 47-64
TAPAS, A., 2016 Transfer Learning for Image Classification and Plant Phenotyping, International Journal of Advanced Research in Computer Engineering & Technology (IJARCET), vol. 5, no.11.
TANG, Y., 2013. Deep Learning Using Linear Support Vector Machines. Contribution to the ICML 2013 Challenges in Representation Learning Workshop arXiv preprint arXiv:1306.0239.
UÇAR, A. ve BİNGÖL, M., 2018. Derin Öğrenmenin Caffe Kullanılarak Grafik İşleme Kartlarında Değerlendirilmesi. Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi 9, pp: 39-49.
ULU, A. ve EKENEL, H. K., 2016. Evrişimsel Sinir Ağı Öznitelikleri ile Kişiyi Yeniden Tanıma. 24th Signal Processing and Communication Application Conference
ÜZEN, H., YEROĞLU, C ve HANBAY,D., 2019. Development of CNN architecture for Honey Bees Disease Condition. In: 2019 International Artificial Intelligence and Data Processing Symposium (IDAP). IEEE, p. 1-5.
YAHOO RESEARCH LABS, 2013. Yahoo! Shopping Shoes Image Content.
YILMAZ, M., 2017. Mikroskobik Görüntüler Üzerinde Derin Öğrenme Algoritmaları Kullanarak Hastalıklı Hücrelerin Otomatik Tanımlanması. Necmettin Erbakan Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 65s.
ZEILER, M. D. and FERGUS, R., 2013. Stochastic Pooling For Regularization Of Deep Convolutional Neural Networks. arXiv preprint arXiv:1301.3557.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı **:** Fatma Yeşim AYDİLEK

Uyruğu **:** Türkiye Cumhuriyeti

Doğum Tarihi ve Yeri **:** 1989 – Darende / MALATYA

e-mail **:** fyaydilek@harran.edu.tr

EĞİTİM

Derece	**Adı, İlçe, İl**	**Bitirme Yılı**
Lise	Darende Lisesi, Darende, Malatya	2006
Üniversite	Selçuk Üniversitesi, Konya	2012

UZMANLIK ALANLARI

C, C#, ASP.NET, Delphi, Oracle, Yapay Zeka Uygulamaları, Web tasarım.

YAYINLAR

AYDİLEK FATMA YEŞİM, GÜMÜŞÇÜ ABDÜLKADİR (2018). Transfer Öğrenme Kullanılarak Öznitelik Çıkarma ve Seçme Yöntemlerinin Karşılaştırılması. VI. ULUSLARARASI GAP MÜHENDİSLİK KONGRESİ (Tam Metin Bildiri/Sözlü Sunum)